



Bonnes pratiques en matière d'optimisation des performances AWS Glue pour les tâches Apache Spark



: Bonnes pratiques en matière d'optimisation des performances AWS

Glue pour les tâches Apache Spark

Table of Contents

Introduction	1
Sujets clés	2
Architecture	2
Ensemble de données distribué résilient	3
Évaluation paresseuse	5
Terminologie des applications Spark	6
Parallelism	7
Optimiseur de catalyseurs	8
Étudier les problèmes de performance	11
Identifiez les goulots d'étranglement à l'aide de l'interface utilisateur Spark	11
Stratégies pour optimiser les performances	13
Stratégie de base pour le réglage des performances	13
Pratiques d'optimisation pour les performances professionnelles de Spark	14
Augmenter la capacité du cluster	15
CloudWatch métriques	15
Interface utilisateur Spark	16
Utilisez la dernière version	18
Réduisez le volume de données numérisées	18
CloudWatch métriques	19
Interface utilisateur Spark	19
Paralléliser les tâches	29
CloudWatch métriques	29
Interface utilisateur Spark	30
Optimisez les shuffles	36
CloudWatch métriques	37
Interface utilisateur Spark	37
Minimiser les frais de planification	46
CloudWatch métriques	46
Interface utilisateur Spark	47
Optimisation des fonctions définies par l'utilisateur	48
Python standard UDF	50
Vectorisé UDF	50
Étincelle SQL	51
Utiliser les pandas pour les mégadonnées	52

Ressources	53
Historique du document	54
Glossaire	55
#	55
A	56
B	59
C	61
D	64
E	69
F	71
G	72
H	73
I	75
L	77
M	78
O	83
P	85
Q	88
R	89
S	91
T	95
U	97
V	97
W	98
Z	99
.....	c

Bonnes pratiques en matière d'optimisation des performances AWS Glue pour les tâches Apache Spark

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

Décembre 2023 ([historique du document](#))

AWS Glue propose différentes options pour optimiser les performances. Ce guide définit les principaux sujets relatifs au réglage AWS Glue d'Apache Spark. Il fournit ensuite une stratégie de base à suivre lors de leur réglage AWS Glue pour les tâches Apache Spark. Utilisez ce guide pour apprendre à identifier les problèmes de performance en interprétant les métriques disponibles dans AWS Glue. Intégrez ensuite des stratégies pour résoudre ces problèmes, en maximisant les performances et en minimisant les coûts.

Ce guide couvre les pratiques de réglage suivantes :

- [Augmentez la capacité du cluster](#)
- [Utilisez la dernière AWS Glue version](#)
- [Réduisez le volume de données numérisées](#)
- [Paralléliser les tâches](#)
- [Minimiser les frais de planification](#)
- [Optimisez les shuffles](#)
- [Optimisation des fonctions définies par l'utilisateur](#)

Sujets clés d'Apache Spark

Cette section explique les concepts de base d'Apache Spark et les principaux sujets relatifs à l'optimisation AWS Glue des performances d'Apache Spark. Il est important de comprendre ces concepts et sujets avant de discuter de stratégies de réglage réelles.

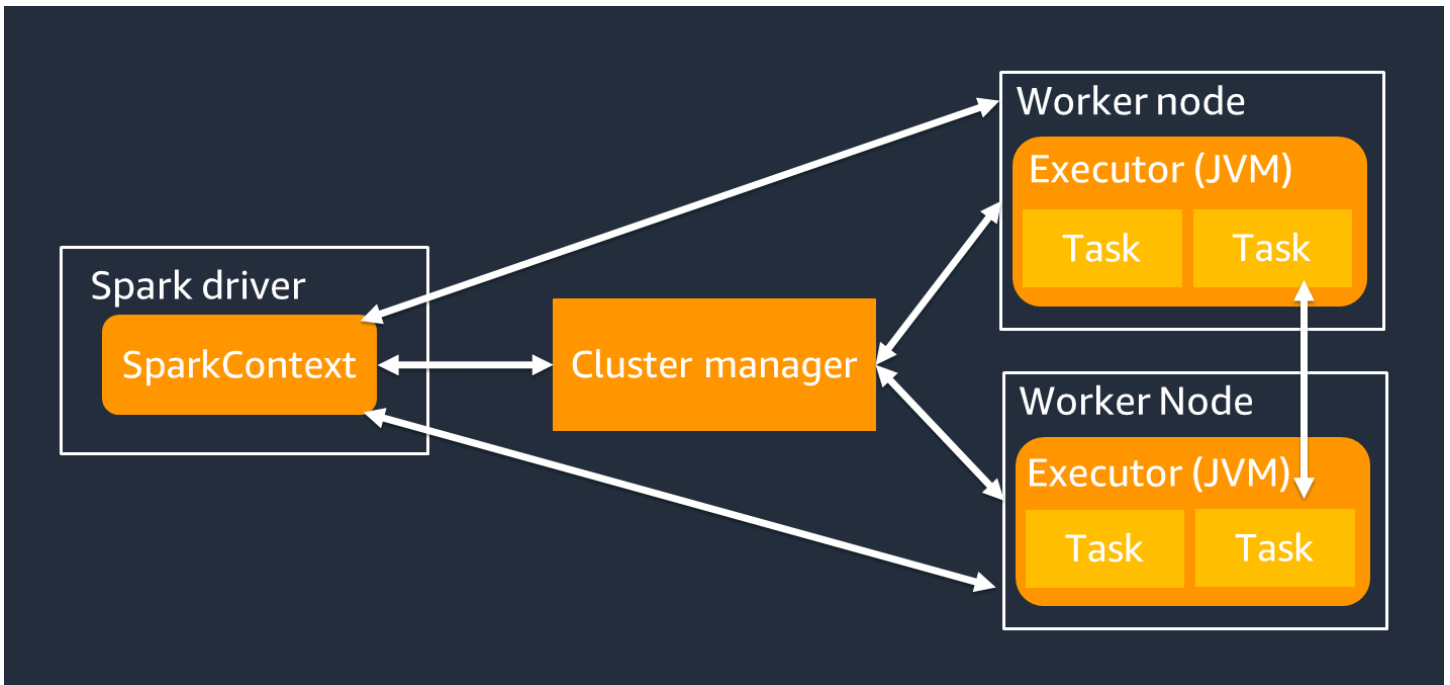
Architecture

Le pilote Spark est principalement chargé de diviser votre application Spark en tâches pouvant être exécutées par des travailleurs individuels. Le pilote Spark a les responsabilités suivantes :

- Exécution `main()` de votre code
- Génération de plans d'exécution
- Provisionner les exécuteurs Spark conjointement avec le gestionnaire de cluster, qui gère les ressources du cluster
- Planification de tâches et demande de tâches pour les exécuteurs Spark
- Gestion de la progression et de la reprise des tâches

Vous utilisez un `SparkContext` objet pour interagir avec le pilote Spark lors de l'exécution de votre tâche.

Un exécuteur Spark est un outil destiné à conserver des données et à exécuter des tâches transmises par le pilote Spark. Le nombre d'exécuteurs Spark augmentera ou diminuera en fonction de la taille de votre cluster.




Note

Un exécuteur Spark possède plusieurs emplacements, de sorte que plusieurs tâches peuvent être traitées en parallèle. Spark prend en charge une tâche pour chaque cœur de processeur virtuel (vCPU) par défaut. Par exemple, si un exécuteur possède quatre cœurs de processeur, il peut exécuter quatre tâches simultanément.

Ensemble de données distribué résilient

Spark effectue la tâche complexe de stockage et de suivi de grands ensembles de données entre les exécuteurs Spark. Lorsque vous écrivez du code pour des tâches Spark, vous n'avez pas à vous soucier des détails du stockage. Spark fournit l'abstraction du jeu de données distribué résilient (RDD), qui est un ensemble d'éléments qui peuvent être utilisés en parallèle et qui peuvent être partitionnés entre les exécuteurs Spark du cluster.

La figure suivante montre la différence entre la manière de stocker les données en mémoire lorsqu'un script Python est exécuté dans son environnement typique et lorsqu'il est exécuté dans le framework Spark (PySpark).



- Python — L'écriture `val = [1,2,3...N]` dans un script Python permet de conserver les données en mémoire sur la seule machine sur laquelle le code est exécuté.
- PySpark— Spark fournit la structure de données RDD pour charger et traiter les données distribuées dans la mémoire sur plusieurs exécuteurs Spark. Vous pouvez générer un RDD avec un code tel que `rdd = sc.parallelize[1,2,3...N]`, et Spark peut automatiquement distribuer et conserver les données en mémoire entre plusieurs exécuteurs Spark.

Dans de nombreuses AWS Glue tâches, vous utilisez RDDs Through AWS Glue DynamicFrameset Spark DataFrames. Il s'agit d'abstractions qui vous permettent de définir le schéma des données dans un RDD et d'effectuer des tâches de niveau supérieur avec ces informations supplémentaires. Comme ils utilisent des RDD en interne, les données sont distribuées de manière transparente et chargées sur plusieurs nœuds dans le code suivant :

- 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>")
```

Un RDD possède les caractéristiques suivantes :

- Les RDD sont constitués de données divisées en plusieurs parties appelées partitions. Chaque exécuteur Spark stocke une ou plusieurs partitions en mémoire, et les données sont réparties entre plusieurs exécuteurs.
- Les RDD sont immuables, ce qui signifie qu'ils ne peuvent pas être modifiés après leur création. Pour modifier a DataFrame, vous pouvez utiliser des transformations définies dans la section suivante.
- Les RDD répliquent les données sur les nœuds disponibles, afin qu'ils puissent récupérer automatiquement les données en cas de défaillance des nœuds.

Évaluation paresseuse

Les RDD prennent en charge deux types d'opérations : les transformations, qui créent un nouvel ensemble de données à partir d'un ensemble de données existant, et les actions, qui renvoient une valeur au programme pilote après avoir exécuté un calcul sur l'ensemble de données.

- Transformations — Les RDD étant immuables, vous ne pouvez les modifier qu'à l'aide d'une transformation.

Par exemple, map il s'agit d'une transformation qui fait passer chaque élément de l'ensemble de données par le biais d'une fonction et renvoie un nouveau RDD représentant les résultats. Notez que la map méthode ne renvoie pas de sortie. Spark stocke la transformation abstraite pour le futur, au lieu de vous laisser interagir avec le résultat. Spark n'agira pas sur les transformations tant que vous n'aurez pas appelé une action.

- Actions — À l'aide de transformations, vous élaborez votre plan de transformation logique. Pour lancer le calcul, vous devez exécuter une action telle que `write`, `countshow`, ou `collect`.


Toutes les transformations dans Spark sont paresseuses, en ce sens qu'elles ne calculent pas leurs résultats immédiatement. Spark mémorise plutôt une série de transformations appliquées à certains ensembles de données de base, tels que les objets Amazon Simple Storage Service

(Amazon S3). Les transformations sont calculées uniquement lorsqu'une action nécessite le renvoi d'un résultat au pilote. Cette conception permet à Spark de fonctionner plus efficacement. Par exemple, considérez la situation dans laquelle un ensemble de données créé par le biais de la map transformation n'est consommé que par une transformation qui réduit considérablement le nombre de lignes, telle que `reduce`. Vous pouvez ensuite transmettre le plus petit jeu de données qui a subi les deux transformations au pilote, au lieu de transmettre le plus grand jeu de données mappé.

Terminologie des applications Spark

Cette section couvre la terminologie de l'application Spark. Le pilote Spark crée un plan d'exécution et contrôle le comportement des applications dans plusieurs abstractions. Les termes suivants sont importants pour le développement, le débogage et le réglage des performances avec l'interface utilisateur Spark.

- **Application** : basée sur une session Spark (contexte Spark). Identifié par un identifiant unique tel que `<application_XXX>`.
- **Emplois** : basés sur les actions créées pour un RDD. Une tâche comprend une ou plusieurs étapes.
- **Étapes** : basées sur les shuffles créés pour un RDD. Une étape comprend une ou plusieurs tâches. Le shuffle est le mécanisme de Spark pour redistribuer les données afin qu'elles soient regroupées différemment entre les partitions RDD. Certaines transformations, par exemple `join()`, nécessitent un remaniement. Les shuffles sont abordés plus en détail dans la section Pratique de réglage [Optimize shuffles](#).
- **Tâches** — Une tâche est l'unité minimale de traitement planifiée par Spark. Des tâches sont créées pour chaque partition RDD, et le nombre de tâches est le nombre maximum d'exécutions simultanées dans la phase.




Note

Les tâches sont l'élément le plus important à prendre en compte lors de l'optimisation du parallélisme. Le nombre de tâches varie en fonction du nombre de RDD

Parallelism

Spark parallélise les tâches de chargement et de transformation des données.

Prenons un exemple dans lequel vous effectuez un traitement distribué de fichiers journaux d'accès (nommés `accesslog1` ... `accesslogN`) sur Amazon S3. Le schéma suivant montre le flux de traitement distribué.

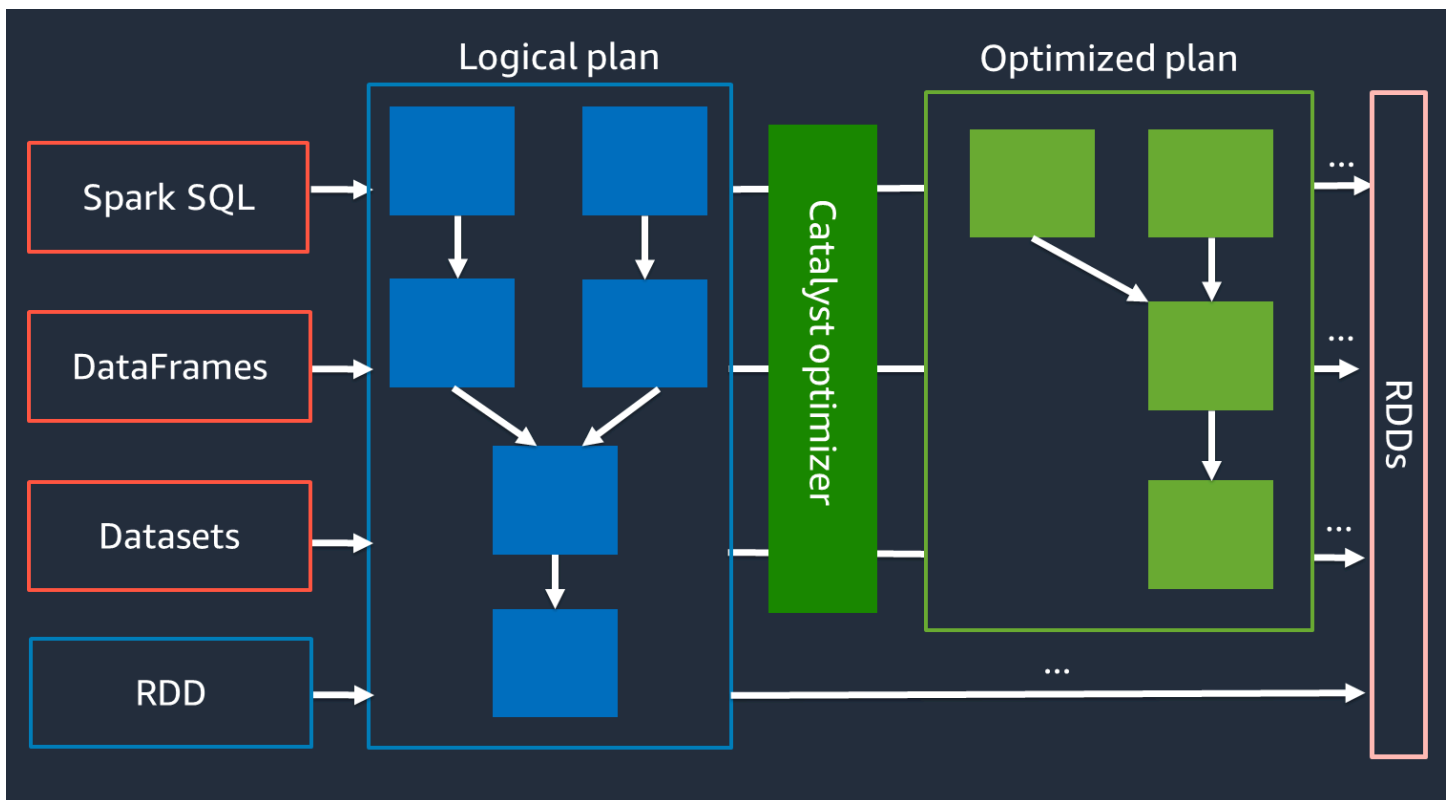


1. Le pilote Spark crée un plan d'exécution pour le traitement distribué entre de nombreux exécuteurs Spark.
2. Le pilote Spark attribue des tâches à chaque exécuteur en fonction du plan d'exécution. Par défaut, le pilote Spark crée des partitions RDD (chacune correspondant à une tâche Spark) pour chaque objet S3 (Part1 . . . N). Le pilote Spark assigne ensuite des tâches à chaque exécuteur.
3. Chaque tâche Spark télécharge l'objet S3 qui lui est attribué et le stocke en mémoire dans la partition RDD. Ainsi, plusieurs exécuteurs Spark téléchargent et traitent la tâche qui leur est assignée en parallèle.

Pour plus de détails sur le nombre initial de partitions et l'optimisation, consultez la section [Paralléliser les tâches](#).

Optimiseur de catalyseurs

En interne, Spark utilise un moteur appelé [optimiseur Catalyst](#) pour optimiser les plans d'exécution. Catalyst dispose d'un optimiseur de requêtes que vous pouvez utiliser lors de l'exécution d'API Spark de haut niveau [DataFrame](#), telles que [Spark SQL](#) et [Datasets](#), comme décrit dans le schéma suivant.



Comme l'optimiseur Catalyst ne fonctionne pas directement avec l'API RDD, les API de haut niveau sont généralement plus rapides que les API RDD de bas niveau. Pour les jointures complexes, l'optimiseur Catalyst peut améliorer considérablement les performances en optimisant le plan d'exécution des tâches. Vous pouvez voir le plan optimisé de votre tâche Spark dans l'onglet SQL de l'interface utilisateur de Spark.

Exécution adaptative des requêtes

L'optimiseur Catalyst effectue l'optimisation de l'exécution par le biais d'un processus appelé Adaptive Query Execution. L'exécution adaptative des requêtes utilise les statistiques d'exécution pour réoptimiser le plan d'exécution des requêtes pendant l'exécution de votre tâche. L'exécution adaptative des requêtes propose plusieurs solutions aux problèmes de performances, notamment la fusion de partitions post-shuffle, la conversion de la jointure par tri-fusion en jointure de diffusion et l'optimisation des jointures asymétriques, comme décrit dans les sections suivantes.

L'exécution adaptative des requêtes est disponible dans la AWS Glue version 3.0 et les versions ultérieures, et elle est activée par défaut dans la AWS Glue version 4.0 (Spark 3.3.0) et les versions ultérieures. L'exécution adaptative des requêtes peut être activée ou désactivée en l'utilisant `spark.conf.set("spark.sql.adaptive.enabled", "true")` dans votre code.

Cloisons post-shuffle fusionnées

Cette fonctionnalité réduit les partitions RDD (coalesce) après chaque shuffle en fonction des statistiques de sortie. Cela simplifie le réglage du numéro de partition shuffle lors de l'exécution de requêtes. Il n'est pas nécessaire de définir un numéro de partition shuffle adapté à votre ensemble de données. Spark peut choisir le numéro de partition shuffle approprié lors de l'exécution une fois que vous avez un nombre initial de partitions shuffle suffisamment important.

La fusion des partitions post-shuffle est activée lorsque les deux sont activées `spark.sql.adaptive.enabled` et `spark.sql.adaptive.coalescePartitions.enabled` sont définies sur `true`. Pour plus d'informations, consultez la [documentation d'Apache Spark](#).

Conversion d'une jointure sort-merge en jointure de diffusion

Cette fonctionnalité reconnaît lorsque vous joignez deux ensembles de données de taille sensiblement différente et adopte un algorithme de jointure plus efficace basé sur ces informations. Pour plus de détails, consultez la [documentation d'Apache Spark](#). Les stratégies de jointure sont abordées dans la section [Optimiser les shuffles](#).

Optimisation des jointures asymétriques

L'asymétrie des données est l'un des obstacles les plus courants pour les tâches Spark. Il décrit une situation dans laquelle les données sont orientées vers des partitions RDD spécifiques (et, par conséquent, vers des tâches spécifiques), ce qui retarde le temps de traitement global de l'application. Cela peut souvent dégrader les performances des opérations de jointure. La fonction d'optimisation des jointures asymétriques gère dynamiquement l'asymétrie des jointures par tri-fusion en divisant (et en répliquant si nécessaire) les tâches asymétriques en tâches à peu près de même taille.

Cette fonctionnalité est activée lorsqu'elle `spark.sql.adaptive.skewJoin.enabled` est définie sur `true`. Pour plus de détails, consultez la [documentation d'Apache Spark](#). L'asymétrie des données est abordée plus en détail dans la section [Optimisation des mélanges](#).

Étudiez les problèmes de performances à l'aide de l'interface utilisateur Spark

Avant d'appliquer les meilleures pratiques pour optimiser les performances de vos AWS Glue tâches, nous vous recommandons vivement de profiler les performances et d'identifier les obstacles. Cela vous aidera à vous concentrer sur les bonnes choses.

Pour une analyse rapide, [CloudWatch les statistiques Amazon](#) fournissent une vue de base des statistiques de vos offres d'emploi. L'[interface utilisateur de Spark](#) fournit une vue plus approfondie pour le réglage des performances. Pour utiliser l'interface utilisateur Spark avec AWS Glue, vous devez [activer l'interface utilisateur Spark pour vos AWS Glue tâches](#). Une fois familiarisé avec l'interface utilisateur de Spark, suivez les [stratégies pour optimiser les performances de Spark au travail](#) afin d'identifier et de réduire l'impact des goulots d'étranglement en fonction de vos résultats.

Identifiez les goulots d'étranglement à l'aide de l'interface utilisateur Spark

Lorsque vous ouvrez l'interface utilisateur Spark, les applications Spark sont répertoriées dans un tableau. Par défaut, le nom de l'application AWS Glue d'une tâche est nativespark-<Job Name>-<Job Run ID>. Choisissez l'application Spark cible en fonction de l'ID d'exécution de la tâche pour ouvrir l'onglet Tâches. Les exécutions de tâches incomplètes, telles que les exécutions de tâches en streaming, sont répertoriées dans Afficher les candidatures incomplètes.

L'onglet Tâches affiche un résumé de toutes les tâches de l'application Spark. Pour déterminer les échecs d'une étape ou d'une tâche, vérifiez le nombre total de tâches. Pour trouver les goulots d'étranglement, triez en choisissant Durée. Accédez aux détails des tâches de longue durée en cliquant sur le lien affiché dans la colonne Description.

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

La page Details for Job répertorie les étapes. Sur cette page, vous pouvez consulter des informations générales telles que la durée, le nombre de tâches réussies et le nombre total de tâches, le nombre d'entrées et de sorties, ainsi que la quantité de lecture et d'écriture aléatoire.

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 Pages. Jump to . Show 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	

L'onglet Executor indique en détail la capacité du cluster Spark. Vous pouvez vérifier le nombre total de cœurs. Le cluster illustré dans la capture d'écran suivante contient 316 cœurs actifs et 512 cœurs au total. Par défaut, chaque cœur peut traiter une tâche Spark à la fois.

Executors

▶ Show Additional Metrics

Summary

	RDD Blocks	Storage Memory	Disk Used	Cores	Active Tasks	Failed Tasks	Complete Tasks	Total Tasks
Active(80)	0	0.0 B / 465.9 GiB	0.0 B	316	10	0	2399	2399
Dead(49)	0	0.0 B / 285.4 GiB	0.0 B	196	10	0	3	3
Total(129)	0	0.0 B / 751.3 GiB	0.0 B	512	10	0	2402	2402

D'après la valeur 5/5 indiquée sur la page Détails du job, l'étape 5 est la plus longue, mais elle n'utilise que 5 cœurs sur 512. Comme le parallélisme de cette étape est très faible, mais qu'elle prend beaucoup de temps, vous pouvez l'identifier comme un goulot d'étranglement. Pour améliorer les performances, vous devez comprendre pourquoi. Pour en savoir plus sur la manière de reconnaître et de réduire l'impact des problèmes de performance courants, consultez la section [Stratégies d'optimisation des performances au travail dans Spark](#).

Stratégies pour optimiser les performances professionnelles de Spark

Lors de la préparation du réglage des paramètres, tenez compte des bonnes pratiques suivantes :

- Déterminez vos objectifs de performance avant de commencer à identifier les problèmes.
- Utilisez des métriques pour identifier les problèmes avant de tenter de modifier les paramètres de réglage.

Pour obtenir des résultats plus cohérents lors du réglage d'une tâche, élaborer une stratégie de base pour votre travail de réglage.

Stratégie de base pour le réglage des performances

En général, le réglage des performances est effectué dans le flux de travail suivant :

1. Déterminez les objectifs de performance.
2. Mesurez les métriques.
3. Identifiez les goulots d'étranglement.
4. Réduisez l'impact des goulots d'étranglement.
5. Répétez les étapes 2 à 4 jusqu'à ce que vous atteigniez l'objectif prévu.

Tout d'abord, déterminez vos objectifs de performance. Par exemple, l'un de vos objectifs peut être de terminer l'exécution d'une AWS Glue tâche en 3 heures. Après avoir défini vos objectifs, mesurez les indicateurs de performance au travail. Identifiez les tendances en matière de métriques et les goulots d'étranglement pour atteindre les objectifs. En particulier, l'identification des goulots d'étranglement est essentielle pour le dépannage, le débogage et le réglage des performances. Pendant l'exécution d'une application Spark, Spark enregistre le statut et les statistiques de chaque tâche dans le journal des événements Spark.

Dans AWS Glue, vous pouvez consulter les métriques de Spark via l'[interface utilisateur Web de Spark](#) fournie par le serveur d'historique Spark. AWS Glue pour les tâches Spark, vous pouvez envoyer [les journaux d'événements Spark](#) à un emplacement que vous spécifiez dans Amazon S3. AWS Glue fournit également un exemple de [AWS CloudFormation modèle](#) et de [Dockerfile](#) pour

démarrer le serveur d'historique Spark sur une EC2 instance Amazon ou sur votre ordinateur local, afin que vous puissiez utiliser l'interface utilisateur de Spark avec les journaux d'événements.

Une fois que vous avez défini vos objectifs de performance et identifié les indicateurs permettant d'évaluer ces objectifs, vous pouvez commencer à identifier et à corriger les obstacles en utilisant les stratégies décrites dans les sections suivantes.

Pratiques d'optimisation pour les performances professionnelles de Spark

Vous pouvez utiliser les stratégies suivantes pour optimiser les performances AWS Glue des tâches Spark :

- AWS Glue ressources :
 - [Augmenter la capacité du cluster](#)
 - [Utilisez la dernière AWS Glue version](#)
- Applications Spark :
 - [Réduisez le volume de données numérisées](#)
 - [Paralléliser les tâches](#)
 - [Optimisez les shuffles](#)
 - [Minimiser les frais de planification](#)
 - [Optimisation des fonctions définies par l'utilisateur](#)

Avant d'utiliser ces stratégies, vous devez avoir accès aux métriques et à la configuration de votre tâche Spark. Vous trouverez ces informations dans la [AWS Glue documentation](#).

Du point de vue AWS Glue des ressources, vous pouvez améliorer les performances en ajoutant AWS Glue des collaborateurs et en utilisant la dernière AWS Glue version.

Du point de vue de l'application Apache Spark, vous avez accès à plusieurs stratégies susceptibles d'améliorer les performances. Si des données inutiles sont chargées dans le cluster Spark, vous pouvez les supprimer pour réduire la quantité de données chargées. Si vous avez sous-utilisé les ressources du cluster Spark et que vos E/S de données sont faibles, vous pouvez identifier les tâches à paralléliser. Vous souhaitez peut-être également optimiser les opérations de transfert de données lourdes, telles que les jointures, si elles prennent beaucoup de temps. Vous pouvez également

optimiser votre plan de requêtes d'emploi ou réduire la complexité informatique des tâches Spark individuelles.

Pour appliquer efficacement ces stratégies, vous devez déterminer quand elles sont applicables en consultant vos indicateurs. Pour plus de détails, consultez chacune des sections suivantes. Ces techniques permettent non seulement d'optimiser les performances, mais également de résoudre des problèmes courants tels que les erreurs out-of-memory (OOM).


Augmenter la capacité du cluster

Si votre travail prend trop de temps, mais que les exécuteurs consomment suffisamment de ressources et que Spark crée un volume important de tâches par rapport aux cœurs disponibles, pensez à augmenter la capacité du cluster. Pour déterminer si cela est approprié, utilisez les mesures suivantes.

CloudWatch métriques

- Vérifiez l'utilisation de la CPUcharge et de la mémoire pour déterminer si les exécuteurs consomment suffisamment de ressources.
- Vérifiez la durée de la tâche pour déterminer si le temps de traitement est trop long pour atteindre vos objectifs de performance.

Dans l'exemple suivant, quatre exécuteurs exécutent une CPU charge supérieure à 97 %, mais le traitement n'est pas terminé au bout de trois heures environ.



Note

Si CPU la charge est faible, vous ne bénéficierez probablement pas de l'augmentation de la capacité du cluster.

Interface utilisateur Spark

Dans l'onglet Job ou Stage, vous pouvez voir le nombre de tâches pour chaque tâche ou étape. Dans l'exemple suivant, Spark a créé 58100 des tâches.

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

Dans l'onglet Exécuteur, vous pouvez voir le nombre total d'exécuteurs et de tâches. Dans la capture d'écran suivante, chaque exécuteur Spark possède quatre cœurs et peut effectuer quatre tâches simultanément.

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

Dans cet exemple, le nombre de tâches Spark (58100) est bien supérieur aux 16 tâches que les exécuteurs peuvent traiter simultanément (4 exécuteurs × 4 cœurs).

Si vous observez ces symptômes, envisagez de redimensionner le cluster. Vous pouvez augmenter la capacité du cluster à l'aide des options suivantes :

- Enable AWS Glue Auto Scaling — [Auto Scaling](#) est disponible pour vos tâches AWS Glue d'extraction, de transformation, de chargement (ETL) et de streaming dans AWS Glue la version 3.0 ou ultérieure. AWS Glue ajoute et supprime automatiquement des travailleurs du cluster en

fonction du nombre de partitions à chaque étape ou de la vitesse à laquelle les microbatches sont générés lors de l'exécution de la tâche.

Si vous observez une situation dans laquelle le nombre de travailleurs n'augmente pas même si Auto Scaling est activé, envisagez d'ajouter des travailleurs manuellement. Notez toutefois que le dimensionnement manuel pour une étape peut entraîner l'inactivité de nombreux travailleurs au cours des étapes ultérieures, ce qui coûte plus cher pour un gain de performance nul.

Après avoir activé Auto Scaling, vous pouvez voir le nombre d'exécuteurs dans les métriques des CloudWatch exécuteurs. Utilisez les mesures suivantes pour surveiller la demande d'exécuteurs dans les applications Spark :

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

Pour plus d'informations sur les métriques, consultez la section [Surveillance AWS Glue à l'aide CloudWatch des métriques Amazon](#).

- **Élargissement** : augmentation du nombre de AWS Glue travailleurs — Vous pouvez augmenter manuellement le nombre de AWS Glue travailleurs. Ajoutez des travailleurs uniquement jusqu'à ce que vous observiez des travailleurs inactifs. À ce stade, l'ajout de travailleurs augmentera les coûts sans améliorer les résultats. Pour plus d'informations, consultez [Paralléliser les tâches](#).
- **Élargissement** : utilisez un type de travail plus important : vous pouvez modifier manuellement le type d'instance de vos AWS Glue collaborateurs afin d'utiliser des travailleurs dotés d'un plus grand nombre de cœurs, de mémoire et d'espace de stockage. Les types de travailleurs plus importants vous permettent d'effectuer une mise à l'échelle verticale et d'exécuter des tâches d'intégration de données intensives, telles que des transformations de données gourmandes en mémoire, des agrégations asymétriques et des contrôles de détection d'entités impliquant des pétaoctets de données.

La mise à l'échelle est également utile dans les cas où le pilote Spark a besoin d'une capacité plus importante, par exemple parce que le plan de requêtes de tâches est assez volumineux. Pour plus d'informations sur les types de travailleurs et leurs performances, consultez le billet de blog consacré au AWS Big Data [Scale your AWS Glue for Apache Spark jobs with new larger worker types G.4X et G.8X](#).

L'utilisation de travailleurs de plus grande taille peut également réduire le nombre total de travailleurs nécessaires, ce qui augmente les performances en réduisant le remaniement dans les opérations intensives telles que les jointures.

Utilisez la dernière AWS Glue version

Nous vous recommandons d'utiliser la dernière AWS Glue version. Plusieurs optimisations et mises à niveau intégrées à chaque version peuvent automatiquement améliorer les performances au travail. Par exemple, la AWS Glue version 4.0 fournit les nouvelles fonctionnalités suivantes :

- Le nouveau moteur d'exécution Apache Spark 3.3.0 — AWS Glue 4.0 s'appuie sur le moteur d'exécution Apache Spark 3.3.0, apportant des améliorations de performances comparables à celles de Spark open source. Le runtime Spark 3.3.0 s'appuie sur de nombreuses innovations de Spark 2.x.
- Connecteur Amazon Redshift amélioré : les versions AWS Glue 4.0 et ultérieures permettent l'intégration d'Amazon Redshift à Apache Spark. L'intégration s'appuie sur un connecteur open source existant et l'améliore en termes de performances et de sécurité. L'intégration permet aux applications de fonctionner jusqu'à 10 fois plus rapidement. Pour plus d'informations, consultez le billet de blog sur [l'intégration d'Amazon Redshift à Apache Spark](#).
- SIMD exécution basée sur des lectures vectorisées avec JSON des données : la AWS Glue version 3.0 CSV et les versions ultérieures ajoutent des lecteurs optimisés qui peuvent considérablement accélérer les performances globales du travail par rapport aux lecteurs basés sur des lignes. Pour plus d'informations sur les CSV données, voir [Optimiser les performances de lecture avec un lecteur vectorisé. SIMD CSV](#) Pour plus d'informations sur les JSON données, voir [Utilisation d'un SIMD JSON lecteur vectorisé avec le format de colonne Apache Arrow](#).

Chaque AWS Glue version inclura des mises à niveau de ce type, entre autres, notamment des mises à jour de connecteurs, de pilotes et de bibliothèques. Pour plus d'informations, consultez [AWS Glue les sections versions](#) et [Migration des AWS Glue tâches vers la AWS Glue version 4.0](#).

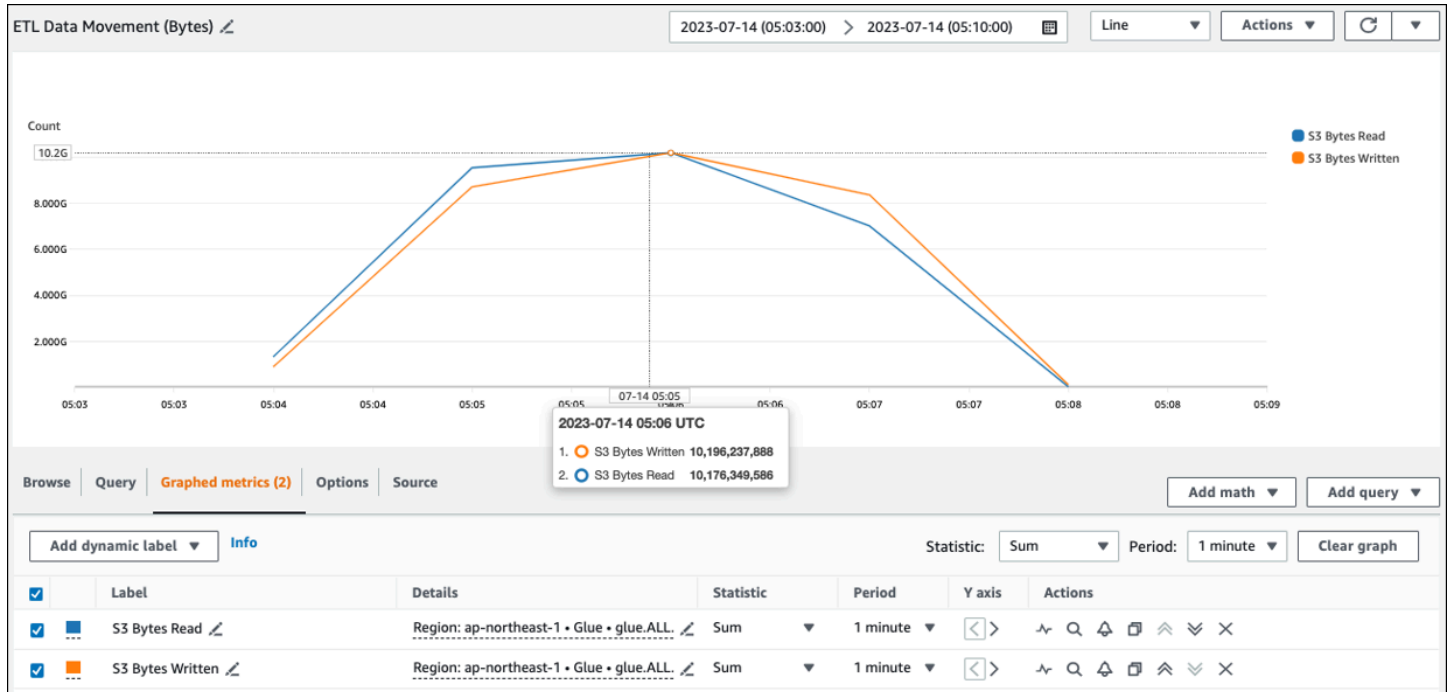
Réduisez le volume de données numérisées

Pour commencer, pensez à charger uniquement les données dont vous avez besoin. Vous pouvez améliorer les performances simplement en réduisant la quantité de données chargées dans votre cluster Spark pour chaque source de données. Pour évaluer si cette approche est appropriée, utilisez les mesures suivantes.

Vous pouvez vérifier les octets lus depuis Amazon S3 dans [CloudWatch les métriques](#) et obtenir plus de détails dans l'interface utilisateur de Spark, comme décrit dans la section [Spark UI](#).

CloudWatch métriques

Vous pouvez voir la taille de lecture approximative d'Amazon S3 dans [ETL Data Movement \(Bytes\)](#). Cette métrique indique le nombre d'octets lus depuis Amazon S3 par tous les exécuteurs depuis le rapport précédent. Vous pouvez l'utiliser pour surveiller le mouvement ETL des données depuis Amazon S3 et comparer les taux de lecture aux taux d'ingestion provenant de sources de données externes.



Si vous observez un point de données de lecture de S3 octets plus important que prévu, envisagez les solutions suivantes.

Interface utilisateur Spark

Dans l'onglet Stage de l'interface utilisateur AWS Glue de Spark, vous pouvez voir la taille de l'entrée et de la sortie. Dans l'exemple suivant, l'étape 2 lit 47,4 GiB en entrée et 47,7 GiB en sortie, tandis que l'étape 5 lit 61,2 MiB en entrée et 56,6 MiB en sortie.

Stages for All Jobs

Completed Stages: 6

▼ Completed Stages (6)

Page:

1 Pages. Jump to . Sho

Stage Id ▾	Description	Submitted	Duration	Tasks: Succeeded/Total	Input	Output
5	parquet at NativeMethodAccessorImpl.java:0 +details	2023/07/14 05:09:49	15 s	<div style="background-color: #0070C0; color: white; padding: 2px;">414/414</div>	61.2 MiB	56.6 MiB
4	load at NativeMethodAccessorImpl.java:0 +details	2023/07/14 05:09:47	0.6 s	<div style="background-color: #0070C0; color: white; padding: 2px;">1/1</div>		
3	Listing leaf files and directories for 43 paths: s3://amazon-reviews-pds/parquet/product_category=Apparel, ... load at NativeMethodAccessorImpl.java:0 +details	2023/07/14 05:09:46	1 s	<div style="background-color: #0070C0; color: white; padding: 2px;">43/43</div>		
2	parquet at NativeMethodAccessorImpl.java:0 +details	2023/07/14 05:04:36	3.1 min	<div style="background-color: #0070C0; color: white; padding: 2px;">414/414</div>	47.4 GiB	47.7 GiB
1	load at NativeMethodAccessorImpl.java:0 +details	2023/07/14 05:04:31	2 s	<div style="background-color: #0070C0; color: white; padding: 2px;">1/1</div>		
0	Listing leaf files and directories for 43 paths: s3://amazon-reviews-pds/parquet/product_category=Apparel, ... load at NativeMethodAccessorImpl.java:0 +details	2023/07/14 05:04:13	6 s	<div style="background-color: #0070C0; color: white; padding: 2px;">43/43</div>		

Lorsque vous utilisez le Spark SQL ou DataFrame des approches dans le cadre de votre AWS Glue travail, l'onglet SQL/D affiche davantage de statistiques sur ces étapes. Dans ce cas, l'étape 2 indique le nombre de fichiers lus : 430, la taille des fichiers lus : 47,4 GiB et le nombre de lignes de sortie : 160 796 570.

Jobs Stages Storage Environment Executors **SQL / DataFrame**

Details for Query 0

Submitted Time: 2023/07/14 05:04:35
Duration: 3.1 min
Succeeded Jobs: 2

Show the Stage ID and Task ID that corresponds to the max metric

Scan parquet

- number of files read: 430
- scan time total (min, med, max (stageld: taskId))
1.07 h (2.2 s, 7.5 s, 29.4 s (stage 2.0: task 198))
- metadata time: 5 ms
- size of files read: 47.4 GiB
- number of output rows: 160,796,570

WholeStageCodegen (1)

- duration: total (min, med, max (stageld: taskId))
1.53 h (5.4 s, 11.4 s, 38.5 s (stage 2.0: task 198))

ColumnarToRow

- number of output rows: 160,796,570
- number of input batches: 39,600

Si vous constatez une différence de taille importante entre les données que vous lisez et celles que vous utilisez, essayez les solutions suivantes.

Amazon S3

Pour réduire la quantité de données chargées dans votre tâche lors de la lecture depuis Amazon S3, tenez compte de la taille du fichier, de la compression, du format de fichier et de la disposition des fichiers (partitions) de votre ensemble de données. AWS Glue car les tâches Spark sont souvent utilisées pour les ETL données brutes, mais pour un traitement distribué efficace, vous devez inspecter les fonctionnalités du format de votre source de données.

- Taille du fichier — Nous recommandons de maintenir la taille du fichier des entrées et des sorties dans une fourchette modérée (par exemple, 128 Mo). Les fichiers trop petits ou trop volumineux peuvent entraîner des problèmes.

Un grand nombre de petits fichiers sont à l'origine des problèmes suivants :

- Charge d'E/S réseau importante sur Amazon S3 en raison de la surcharge requise pour effectuer des demandes (telles que `ListGet`, ou `Head`) pour de nombreux objets (par rapport à quelques objets qui stockent la même quantité de données).
- Charge d'E/S et de traitement importante sur le pilote Spark, ce qui générera de nombreuses partitions et tâches et entraînera un parallélisme excessif.

En revanche, si le type de fichier n'est pas divisible (par exemple `gzip`) et que les fichiers sont trop volumineux, l'application Spark doit attendre qu'une seule tâche ait terminé de lire le fichier dans son intégralité.


Pour réduire le parallélisme excessif lié à la création d'une tâche Apache Spark pour chaque petit fichier, utilisez le [regroupement de fichiers](#) pour `DynamicFrames`. Cette approche réduit le risque d'une OOM exception de la part du pilote Spark. Pour configurer le regroupement de fichiers, définissez les `groupSize` paramètres `groupFiles` et. L'exemple de code suivant utilise le AWS Glue `DynamicFrame` API dans un ETL script avec ces paramètres.

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

- Compression — Si vos objets S3 se chiffrent en centaines de mégaoctets, pensez à les compresser. Il existe différents formats de compression, que l'on peut globalement classer en deux types :
 - Les formats de compression non fractionnables tels que `gzip` nécessitent que l'intégralité du fichier soit décompressée par un seul utilisateur.
 - Les formats de compression séparables, tels que `bzip2` ou `LZO` (indexé), permettent une décompression partielle d'un fichier, qui peut être parallélisé.

Pour Spark (et les autres moteurs de traitement distribué courants), vous allez diviser votre fichier de données source en fragments que votre moteur peut traiter en parallèle. Ces unités

sont souvent appelées divisions. Une fois que vos données sont dans un format séparable, les AWS Glue lecteurs optimisés peuvent récupérer les divisions d'un objet S3 en offrant la Range possibilité de ne GetObject API récupérer que des blocs spécifiques. Examinez le schéma suivant pour voir comment cela fonctionnerait dans la pratique.



Les données compressées peuvent accélérer considérablement votre application, à condition que les fichiers soient d'une taille optimale ou qu'ils soient séparables. Les petites tailles de données réduisent les données numérisées depuis Amazon S3 et le trafic réseau d'Amazon S3 vers votre cluster Spark. D'autre part, il en faut davantage CPU pour compresser et décompresser les données. La quantité de calcul requise varie en fonction du taux de compression de votre algorithme de compression. Tenez compte de ce compromis lorsque vous choisissez votre format de compression fractionnable.

Note

Bien que les fichiers gzip ne soient généralement pas séparables, vous pouvez compresser des blocs de parquet individuels avec gzip, et ces blocs peuvent être parallélisés.

- Format de fichier — Utilisez un format en colonnes. [Apache Parquet](#) et [Apache ORC](#) sont des formats de données en colonnes populaires. Parcourez et ORC stockez les données de manière

efficace en utilisant la compression basée sur les colonnes, en encodant et en compressant chaque colonne en fonction de son type de données. Pour plus d'informations sur les codages Parquet, consultez la section [Définitions de codage Parquet](#). Les fichiers de parquet sont également séparables.

Les formats en colonnes regroupent les valeurs par colonne et les stockent ensemble dans des blocs. Lorsque vous utilisez des formats en colonnes, vous pouvez ignorer les blocs de données correspondant à des colonnes que vous n'avez pas l'intention d'utiliser. Les applications Spark ne peuvent récupérer que les colonnes dont vous avez besoin. En général, de meilleurs taux de compression ou le fait de sauter des blocs de données permettent de lire moins d'octets depuis Amazon S3, ce qui améliore les performances. Les deux formats prennent également en charge les approches pushdown suivantes pour réduire les E/S :

- Projection pushdown — La projection pushdown est une technique qui permet de récupérer uniquement les colonnes spécifiées dans votre application. Vous spécifiez des colonnes dans votre application Spark, comme indiqué dans les exemples suivants :
 - DataFrame exemple : `df.select("star_rating")`
 - SQLExemple de Spark : `spark.sql("select star_rating from <table>")`
- Pushdown des prédicats — Le pushdown des prédicats est une technique permettant un traitement et des clauses efficaces. WHERE GROUP BY Les deux formats comportent des blocs de données qui représentent les valeurs des colonnes. Chaque bloc contient des statistiques pour le bloc, telles que les valeurs maximales et minimales. Spark peut utiliser ces statistiques pour déterminer si le bloc doit être lu ou ignoré en fonction de la valeur de filtre utilisée dans l'application. Pour utiliser cette fonctionnalité, ajoutez des filtres supplémentaires dans les conditions, comme indiqué dans les exemples suivants :
 - DataFrame exemple : `df.select("star_rating").filter("star_rating < 2")`
 - SQLExemple de Spark : `spark.sql("select * from <table> where star_rating < 2")`
- Disposition des fichiers — En stockant vos données S3 dans des objets dans différents chemins en fonction de la façon dont les données seront utilisées, vous pouvez récupérer efficacement les données pertinentes. Pour plus d'informations, consultez la section [Organisation des objets à l'aide de préfixes](#) dans la documentation Amazon S3. AWS Glue prend en charge le stockage des clés et des valeurs des préfixes Amazon S3 au format `key=value`, en partitionnant vos données selon le chemin Amazon S3. En partitionnant vos données, vous pouvez limiter la quantité de données numérisées par chaque application d'analyse en aval, ce qui améliore les performances et réduit

les coûts. Pour plus d'informations, consultez [la section Gestion des partitions pour ETL la sortie dans AWS Glue](#).

Le partitionnement divise votre table en différentes parties et conserve les données associées dans des fichiers groupés en fonction de valeurs de colonne telles que l'année, le mois et le jour, comme indiqué dans l'exemple suivant.

```
# 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
...
```

Vous pouvez définir des partitions pour votre jeu de données en le modélisant à l'aide d'une table dans le AWS Glue Data Catalog. Vous pouvez ensuite limiter la quantité de données numérisées en utilisant l'élagage des partitions comme suit :

- Pour AWS Glue DynamicFrame, régler `push_down_predicate` (`oucatalogPartitionPredicate`).

```
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'",
)
```

- Pour Spark DataFrame, définissez un chemin fixe pour élaguer les partitions.

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

- Pour SparkSQL, vous pouvez définir la clause `Where` pour supprimer les partitions du catalogue de données.

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

- Pour partitionner par date lorsque vous écrivez vos données avec AWS Glue, vous devez DynamicFrame saisir ou [partitionBy\(\)](#) DataFrame insérer les informations de date dans vos colonnes comme suit. [partitionKeys](#)

- 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>/')
```

Cela peut améliorer les performances des consommateurs de vos données de sortie.

Si vous n'êtes pas autorisé à modifier le pipeline qui crée votre jeu de données en entrée, le partitionnement n'est pas une option. Au lieu de cela, vous pouvez exclure les chemins S3 inutiles en utilisant des modèles globaux. Définissez [des exclusions](#) lors de la lecture DynamicFrame. Par exemple, le code suivant exclut les jours des mois 01 à 09, de l'année 2023.

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

Vous pouvez également définir des exclusions dans les propriétés des tables du catalogue de données :

- Clé : exclusions
- Valeur : ["**year=2023/month=0[1-9]**"]
- Trop de partitions Amazon S3 : évitez de partitionner vos données Amazon S3 sur des colonnes contenant un large éventail de valeurs, comme une colonne d'ID contenant des milliers de valeurs. Cela peut augmenter considérablement le nombre de partitions dans votre bucket, car le nombre de partitions possibles est le produit de tous les champs que vous avez partitionnés. Un trop grand nombre de partitions peut provoquer les effets suivants :

- Latence accrue pour récupérer les métadonnées des partitions à partir du catalogue de données
- Augmentation du nombre de petits fichiers, ce qui nécessite davantage de API requêtes Amazon S3 (List,Get, etHead)

Par exemple, lorsque vous définissez un type de date dans `partitionBy` ou `partitionKeys`, un partitionnement au niveau de la date `yyyy/mm/dd` est adapté à de nombreux cas d'utilisation. Cependant, `yyyy/mm/dd/<ID>` cela peut générer tellement de partitions que cela aurait un impact négatif sur les performances dans leur ensemble.

D'autre part, certains cas d'utilisation, tels que les applications de traitement en temps réel, nécessitent de nombreuses partitions telles que `yyyy/mm/dd/hh`. Si votre cas d'utilisation nécessite des partitions importantes, pensez à utiliser des [index de AWS Glue partition](#) pour réduire le temps de latence lors de la récupération des métadonnées de partition à partir du catalogue de données.

Bases de données et JDBC

Pour réduire l'analyse des données lors de la récupération d'informations dans une base de données, vous pouvez spécifier un `where` prédicat (ou une clause) dans une SQL requête. Les bases de données qui ne fournissent pas d'SQLinterface fourniront leur propre mécanisme d'interrogation ou de filtrage.

Lorsque vous utilisez des connexions Java Database Connectivity (JDBC), fournissez une requête de sélection avec la `where` clause pour les paramètres suivants :

- Pour `DynamicFrame`, utilisez l'[sampleQuery](#) option. Lors de l'utilisation `create_dynamic_frame.from_catalog`, configurez l'`additional_options` argument comme suit.

```
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"
)

```

Quand using `create_dynamic_frame.from_options`, configurez l'`connection_options` argument comme suit.

```

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
    }
)

```

- Pour `DataFrame`, utilisez l'option de [requête](#).

```

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()

```

- Pour Amazon Redshift, utilisez la AWS Glue version 4.0 ou une version ultérieure pour bénéficier de la prise en charge du pushdown dans le connecteur [Amazon](#) Redshift Spark.

```

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"}
)

```


)

- Pour les autres bases de données, consultez la documentation de cette base de données.

AWS Glue options

- Pour éviter une analyse complète de toutes les exécutions de tâches en continu et ne traiter que les données absentes lors de la dernière exécution de tâches, activez les [signets de tâches](#).
- Pour limiter la quantité de données d'entrée à traiter, activez l'[exécution limitée](#) avec des signets de tâches. Cela permet de réduire la quantité de données numérisées pour chaque exécution de tâche.


Paralléliser les tâches

Pour optimiser les performances, il est important de paralléliser les tâches de chargement et de transformation des données. Comme nous l'avons indiqué dans la [section Rubriques clés d'Apache Spark](#), le nombre de partitions résilientes d'ensembles de données distribués (RDD) est important, car il détermine le degré de parallélisme. Chaque tâche créée par Spark correspond à une RDD partition sur une base 1:1. Pour obtenir les meilleures performances, vous devez comprendre comment le nombre de RDD partitions est déterminé et comment ce nombre est optimisé.

Si le parallélisme n'est pas suffisant, les symptômes suivants seront enregistrés dans les [CloudWatch métriques](#) et dans l'interface utilisateur de Spark.

CloudWatch métriques

Vérifiez la CPU charge et l'utilisation de la mémoire. Si certains exécuteurs ne traitent pas pendant une phase de votre travail, il convient d'améliorer le parallélisme. Dans ce cas, pendant la période visualisée, l'exécuteur 1 exécutait une tâche, mais pas les autres exécuteurs (2, 3 et 4). Vous pouvez en déduire que le pilote Spark n'a pas assigné de tâches à ces exécuteurs.




Interface utilisateur Spark

Dans l'onglet Stage de l'interface utilisateur de Spark, vous pouvez voir le nombre de tâches d'une étape. Dans ce cas, Spark n'a effectué qu'une seule tâche.

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

En outre, la chronologie des événements montre qu'Executor 1 traite une tâche. Cela signifie que le travail de cette étape a été entièrement effectué sur un exécuteur, tandis que les autres étaient inactifs.



Si vous observez ces symptômes, essayez les solutions suivantes pour chaque source de données.

Paralléliser le chargement de données depuis Amazon S3

Pour paralléliser les chargements de données depuis Amazon S3, vérifiez d'abord le nombre de partitions par défaut. Vous pouvez ensuite déterminer manuellement un nombre cible de partitions, mais veillez à ne pas en avoir trop.

Déterminer le nombre de partitions par défaut

Pour Amazon S3, le nombre initial de RDD partitions Spark (chacune correspondant à une tâche Spark) est déterminé par les caractéristiques de votre ensemble de données Amazon S3 (par exemple, le format, la compression et la taille). Lorsque vous créez un AWS Glue DynamicFrame ou un Spark DataFrame à partir d'CSVobjets stockés dans Amazon S3, le nombre initial de RDD partitions (NumPartitions) peut être approximativement calculé comme suit :

- Taille de l'objet ≤ 64 Mo : NumPartitions = Number of Objects
- Taille de l'objet > 64 Mo : NumPartitions = Total Object Size / 64 MB
- Non séparable (gzip) : NumPartitions = Number of Objects

Comme indiqué dans la section [Réduire la quantité de données numérisées](#), Spark divise les grands objets S3 en divisions qui peuvent être traitées en parallèle. Lorsque la taille de l'objet est supérieure à la taille de la division, Spark divise l'objet et crée une RDD partition (et une tâche) pour chaque division. La taille fractionnée de Spark dépend du format de vos données et de votre environnement d'exécution, mais il s'agit d'une approximation de départ raisonnable. Certains objets sont compressés à l'aide de formats de compression non séparables tels que gzip. Spark ne peut donc pas les diviser.

La NumPartitions valeur peut varier en fonction du format de vos données, de la compression, de AWS Glue la version, du nombre de AWS Glue travailleurs et de la configuration de Spark.

Par exemple, lorsque vous chargez un seul csv.gz objet de 10 Go à l'aide d'un Spark DataFrame, le pilote Spark ne crée qu'une seule RDD partition (NumPartitions=1) car gzip n'est pas divisible. Cela entraîne une charge importante sur un exécuteur Spark en particulier et aucune tâche n'est assignée aux autres exécuteurs, comme décrit dans la figure suivante.

Vérifiez le nombre réel de tâches (NumPartitions) pour l'étape `df.rdd.getNumPartitions()` dans l'onglet [Spark Web UI](#) Stage, ou exécutez votre code pour vérifier le parallélisme.

Lorsque vous trouvez un fichier gzip de 10 Go, vérifiez si le système qui génère ce fichier peut le générer dans un format divisible. Si ce n'est pas possible, vous devrez peut-être augmenter la [capacité du cluster](#) pour traiter le fichier. Pour exécuter des transformations efficaces sur les données que vous avez chargées, vous devez rééquilibrer l'RDDensemble des travailleurs de votre cluster en utilisant la répartition.

Déterminer manuellement un nombre cible de partitions

En fonction des propriétés de vos données et de l'implémentation de certaines fonctionnalités par Spark, vous risquez de vous retrouver avec une faible `NumPartitions` valeur, même si le travail sous-jacent peut toujours être parallélisé. S'il `NumPartitions` est trop petit, exécutez-le `df.repartition(N)` pour augmenter le nombre de partitions afin que le traitement puisse être réparti entre plusieurs exécuteurs Spark.

Dans ce cas, l'exécution `df.repartition(100)` passera `NumPartitions` de 1 à 100, ce qui créera 100 partitions de vos données, chacune dotée d'une tâche pouvant être assignée aux autres exécuteurs.

L'opération `repartition(N)` divise l'ensemble des données de manière égale (10 Go/100 partitions = 100 Mo/partition), évitant ainsi le biais des données vers certaines partitions.

Note

Lorsqu'une opération de shuffle telle qu'elle `join` est exécutée, le nombre de partitions augmente ou diminue dynamiquement en fonction de la valeur de `spark.sql.shuffle.partitions` ou `spark.default.parallelism`. Cela facilite un échange de données plus efficace entre les exécuteurs Spark. Pour plus d'informations, consultez la [documentation de Spark](#).

Lorsque vous déterminez le nombre cible de partitions, votre objectif est de maximiser l'utilisation des AWS Glue travailleurs provisionnés. Le nombre de AWS Glue travailleurs et le nombre de tâches Spark sont liés par le nombre de vCPU. Spark prend en charge une tâche pour chaque CPU vcore. Dans AWS Glue la version 3.0 ou ultérieure, vous pouvez calculer un nombre cible de partitions à l'aide de la formule suivante.

```
# 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
```

Dans cet exemple, chaque worker G-1X fournit quatre CPU cœurs en v à un exécuteur Spark (`spark.executor.cores = 4`). Spark prend en charge une tâche pour chaque v CPU Core, de sorte que les exécuteurs G-1X Spark peuvent exécuter quatre tâches simultanément (`numSlotPerExecutor`). Ce nombre de partitions permet d'utiliser pleinement le cluster si les tâches prennent le même temps. Cependant, certaines tâches prennent plus de temps que d'autres, ce qui crée des cœurs inactifs. Si tel est le cas, envisagez de multiplier `numPartitions` par 2 ou 3 pour répartir et planifier efficacement les tâches fastidieuses.

Trop de partitions

Un nombre excessif de partitions entraîne un nombre excessif de tâches. Cela entraîne une charge importante sur le pilote Spark en raison de la surcharge liée au traitement distribué, comme les tâches de gestion et l'échange de données entre les exécuteurs Spark.

Si le nombre de partitions de votre travail est nettement supérieur au nombre de partitions cible, envisagez de réduire le nombre de partitions. Vous pouvez réduire les partitions en utilisant les options suivantes :

- Si la taille de vos fichiers est très petite, utilisez AWS Glue [groupFiles](#). Vous pouvez réduire le parallélisme excessif résultant du lancement d'une tâche Apache Spark pour traiter chaque fichier.
- `coalesce(N)` À utiliser pour fusionner des partitions. Il s'agit d'un procédé peu coûteux. Lorsque vous réduisez le nombre de partitions, `coalesce(N)` il est préférable de le faire `repartition(N)`, car il `repartition(N)` effectue un shuffle pour répartir de manière égale le nombre d'enregistrements dans chaque partition. Cela augmente les coûts et les frais de gestion.
- Utilisez l'exécution adaptative des requêtes dans Spark 3.x. Comme indiqué dans la section [Rubriques clés d'Apache Spark](#), Adaptive Query Execution fournit une fonction permettant de fusionner automatiquement le nombre de partitions. Vous pouvez utiliser cette approche lorsque vous ne pouvez pas connaître le nombre de partitions tant que vous n'avez pas effectué l'exécution.

Paralléliser le chargement des données depuis JDBC

Le nombre de RDD partitions Spark est déterminé par la configuration. Notez que par défaut, une seule tâche est exécutée pour analyser l'intégralité d'un ensemble de données source par le biais d'une SELECT requête.

Tout comme AWS Glue DynamicFrames Spark, ils DataFrames prennent en charge le chargement de JDBC données parallélisé sur plusieurs tâches. Cela se fait en utilisant des where prédicats pour diviser une SELECT requête en plusieurs requêtes. Pour paralléliser les lectures depuis JDBC, configurez les options suivantes :

- Pour AWS Glue DynamicFrame, régler hashfield (ou hashexpression) et hashpartition. Pour en savoir plus, consultez [Reading from JDBC tables in parallel](#).

```
connection_mysql8_options = {
  "url": "jdbc:mysql://XXXXXXXXXX.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"
)
```

- Pour Spark DataFrame, set numPartitions, partitionColumn, lowerBound, et upperBound. Pour en savoir plus, voir Vers [JDBC d'autres bases de données](#).

```
df = spark.read \
  .format("jdbc") \
  .option("url", "jdbc:mysql://XXXXXXXXXX.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/")
```

Paralléliser le chargement des données depuis DynamoDB lors de l'utilisation du connecteur ETL

Le nombre de RDD partitions Spark est déterminé par le `dynamodb.splits` paramètre. Pour paralléliser les lectures depuis Amazon DynamoDB, configurez les options suivantes :

- Augmentez la valeur de `dynamodb.splits`.
- Optimisez le paramètre en suivant la formule expliquée dans [Types de connexion et options pour ETL in AWS Glue for Spark](#).

Paralléliser le chargement des données depuis Kinesis Data Streams

Le nombre de RDD partitions Spark est déterminé par le nombre de partitions présentes dans le flux de données source Amazon Kinesis Data Streams. Si votre flux de données ne contient que quelques fragments, il n'y aura que quelques tâches Spark. Cela peut entraîner un faible parallélisme dans les processus en aval. Pour paralléliser les lectures depuis Kinesis Data Streams, configurez les options suivantes :

- Augmentez le nombre de partitions pour obtenir plus de parallélisme lors du chargement de données depuis Kinesis Data Streams.
- Si la logique du microlot est suffisamment complexe, envisagez de repartitionner les données au début du lot, après avoir supprimé les colonnes inutiles.

Pour plus d'informations, consultez la section [Meilleures pratiques pour optimiser les coûts et les performances des ETL tâches de AWS Glue streaming](#).

Paralléliser les tâches après le chargement des données

Pour paralléliser les tâches après le chargement des données, augmentez le nombre de RDD partitions à l'aide des options suivantes :

- Répartissez les données pour générer un plus grand nombre de partitions, en particulier juste après le chargement initial si le chargement lui-même ne peut pas être parallélisé.

Appelez `repartition()` soit en `DynamicFrame` activant `DataFrame`, soit en spécifiant le nombre de partitions. En règle générale, deux ou trois fois le nombre de cœurs disponibles est deux ou trois fois supérieur.

Cependant, lors de l'écriture d'une table partitionnée, cela peut entraîner une explosion de fichiers (chaque partition peut potentiellement générer un fichier dans chaque partition de table). Pour éviter cela, vous pouvez le répartir `DataFrame` par colonne. Cela utilise les colonnes de partition de la table afin que les données soient organisées avant d'être écrites. Vous pouvez spécifier un plus grand nombre de partitions sans placer de petits fichiers sur les partitions de la table. Veillez toutefois à éviter toute distorsion des données, dans laquelle certaines valeurs de partition se retrouveraient avec la plupart des données et retarderaient l'exécution de la tâche.

- En cas de shuffles, augmentez la `spark.sql.shuffle.partitions` valeur. Cela peut également aider à résoudre les problèmes de mémoire lors du shuffling.

Lorsque vous avez plus de 2 001 partitions shuffle, Spark utilise un format de mémoire compressé. Si vous avez un nombre proche de celui-ci, vous souhaitez peut-être définir une `spark.sql.shuffle.partitions` valeur supérieure à cette limite pour obtenir une représentation plus efficace.

Optimisez les shuffles

Certaines opérations, telles que `join()` et `groupByKey()`, nécessitent que Spark effectue un shuffle. Le shuffle est le mécanisme utilisé par Spark pour redistribuer les données afin qu'elles soient regroupées différemment selon les partitions. RDD Le remaniement peut aider à remédier aux problèmes de performance. Cependant, comme le shuffling implique généralement de copier des données entre les exécuteurs Spark, le shuffle est une opération complexe et coûteuse. Par exemple, les shuffles génèrent les coûts suivants :

- E/S de disque :
 - Génère un grand nombre de fichiers intermédiaires sur le disque.
- E/S réseau :
 - Nécessite de nombreuses connexions réseau (Nombre de connexions = Mapper × Reducer).


- Les enregistrements étant agrégés dans de nouvelles RDD partitions qui peuvent être hébergées sur un autre exécuteur Spark, une fraction importante de votre ensemble de données peut être déplacée entre les exécuteurs Spark sur le réseau.
- CPU et charge de la mémoire :
 - Trie les valeurs et fusionne des ensembles de données. Ces opérations sont planifiées sur l'exécuteur testamentaire, ce qui impose une lourde charge à celui-ci.

Le shuffle est l'un des principaux facteurs de dégradation des performances de votre application Spark. Lors du stockage des données intermédiaires, cela peut épuiser de l'espace sur le disque local de l'exécuteur, ce qui entraîne l'échec de la tâche Spark.

Vous pouvez évaluer les performances de votre shuffle dans les CloudWatch métriques et dans l'interface utilisateur de Spark.

CloudWatch métriques

Si la valeur écrite de Shuffle Bytes est élevée par rapport à Shuffle Bytes Read, votre tâche Spark peut utiliser des opérations de [brassage](#) telles que `ou. join()` `groupByKey()`



Interface utilisateur Spark

Dans l'onglet Stage de l'interface utilisateur de Spark, vous pouvez vérifier les valeurs Shuffle Read Size/Records. Vous pouvez également le voir dans l'onglet Exécuteurs.

Dans la capture d'écran suivante, chaque exécuteur échange environ 18,6 Go/402 000 enregistrements avec le processus de shuffle, pour une taille totale de lecture par shuffle d'environ 75 Go).

La colonne Shuffle Spill (Disk) indique qu'une grande quantité de mémoire est déversée sur le disque, ce qui peut entraîner un encombrement du disque ou un problème de performance.

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

Si vous observez ces symptômes et que l'étape prend trop de temps par rapport à vos objectifs de performance, ou si elle échoue Out Of Memory ou comporte No space left on device des erreurs, envisagez les solutions suivantes.

Optimisez la jointure

L'`join()` opération, qui consiste à joindre des tables, est l'opération de shuffle la plus couramment utilisée, mais elle constitue souvent un goulot d'étranglement en termes de performances. L'adhésion étant une opération coûteuse, nous vous recommandons de ne pas l'utiliser, sauf si elle est essentielle aux besoins de votre entreprise. Vérifiez que vous utilisez efficacement votre pipeline de données en vous posant les questions suivantes :

- Recalculez-vous une jointure qui est également effectuée dans d'autres tâches que vous pouvez réutiliser ?
- Est-ce que vous joignez pour convertir les clés étrangères en valeurs qui ne sont pas utilisées par les consommateurs de votre sortie ?

Après avoir confirmé que vos opérations d'adhésion sont essentielles aux besoins de votre entreprise, consultez les options suivantes pour optimiser votre adhésion de manière à répondre à vos exigences.

Utilisez le pushdown avant de rejoindre

Filtrez les lignes et les colonnes inutiles DataFrame avant d'effectuer une jointure. Cela présente les avantages suivants :

- Réduit le volume de transfert de données pendant le shuffle
- Réduit la quantité de traitement dans l'exécuteur Spark
- Réduit la quantité de données numérisées

```
# 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"])
```


Utiliser DataFrame Join

Essayez d'utiliser un [Spark de haut niveau API](#) tel que Spark SQL et Datasets au lieu de RDD API ou DynamicFrame join. DataFrame Vous pouvez le DynamicFrame convertir DataFrame en un appel de méthode tel que `df.toDF()`. Comme indiqué dans la section [Sujets clés d'Apache Spark](#), ces opérations de jointure internes tirent parti de l'optimisation des requêtes par l'optimiseur Catalyst.

Mélangez et diffusez des jointures de hachage et des indices

Spark prend en charge deux types de jointure : la jointure automatique et la jointure par hachage par diffusion. Une jointure par hachage de diffusion ne nécessite pas de brassage et peut nécessiter moins de traitement qu'une jointure aléatoire. Cependant, cela ne s'applique que lorsque vous joignez une petite table à une grande. Lorsque vous joignez une table pouvant tenir dans la mémoire d'un seul exécuteur Spark, pensez à utiliser une jointure par hachage de diffusion.

Le schéma suivant montre la structure de haut niveau et les étapes d'une jointure par hachage de diffusion et d'une jointure aléatoire.



Les détails de chaque jointure sont les suivants :

- Joindre le shuffle :
 - La jointure par hachage aléatoire joint deux tables sans les trier et répartit la jointure entre les deux tables. Il convient aux jointures de petites tables qui peuvent être stockées dans la mémoire de l'exécuteur Spark.
 - La jointure sort-merge distribue les deux tables à joindre par clé et les trie avant de les joindre. Il convient aux assemblages de grandes tables.
- Jointure par hachage de diffusion :
 - Une jointure par hachage de diffusion pousse le plus petit RDD ou la table vers chacun des nœuds de travail. Il effectue ensuite une combinaison côté carte avec chaque partition de la plus grande RDD ou de la table.

Il convient aux jointures lorsque l'une de vos RDDs tables peut tenir en mémoire ou peut être conçue pour tenir en mémoire. Il est avantageux d'effectuer une jointure par hachage de diffusion lorsque cela est possible, car cela ne nécessite pas de shuffle. Vous pouvez utiliser un indice de jointure pour demander une participation à une diffusion auprès de Spark comme suit.

```
# 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;
```

Pour plus d'informations sur les conseils de jointure, consultez la section [Conseils de jointure](#).

Dans la AWS Glue version 3.0 et les versions ultérieures, vous pouvez tirer parti des jointures par hachage diffusées automatiquement en activant [l'exécution adaptative des requêtes](#) et des paramètres supplémentaires. L'exécution adaptative des requêtes convertit une jointure par tri-fusion en jointure par hachage de diffusion lorsque les statistiques d'exécution de l'un ou l'autre côté de la jointure sont inférieures au seuil de jointure par hachage adaptatif de diffusion.

Dans la AWS Glue version 3.0, vous pouvez activer l'exécution adaptative des requêtes en configurant `spark.sql.adaptive.enabled=true`. L'exécution adaptative des requêtes est activée par défaut dans AWS Glue 4.0.

Vous pouvez définir des paramètres supplémentaires relatifs aux shuffles et aux jointures de hachage diffusées :

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

Pour plus d'informations sur les paramètres associés, consultez la section [Conversion d'une jointure sort-merge en une jointure de diffusion](#).

Dans la AWS Glue version 3.0 ou ultérieure, vous pouvez utiliser d'autres astuces de jointure pour le shuffle afin d'ajuster votre comportement.

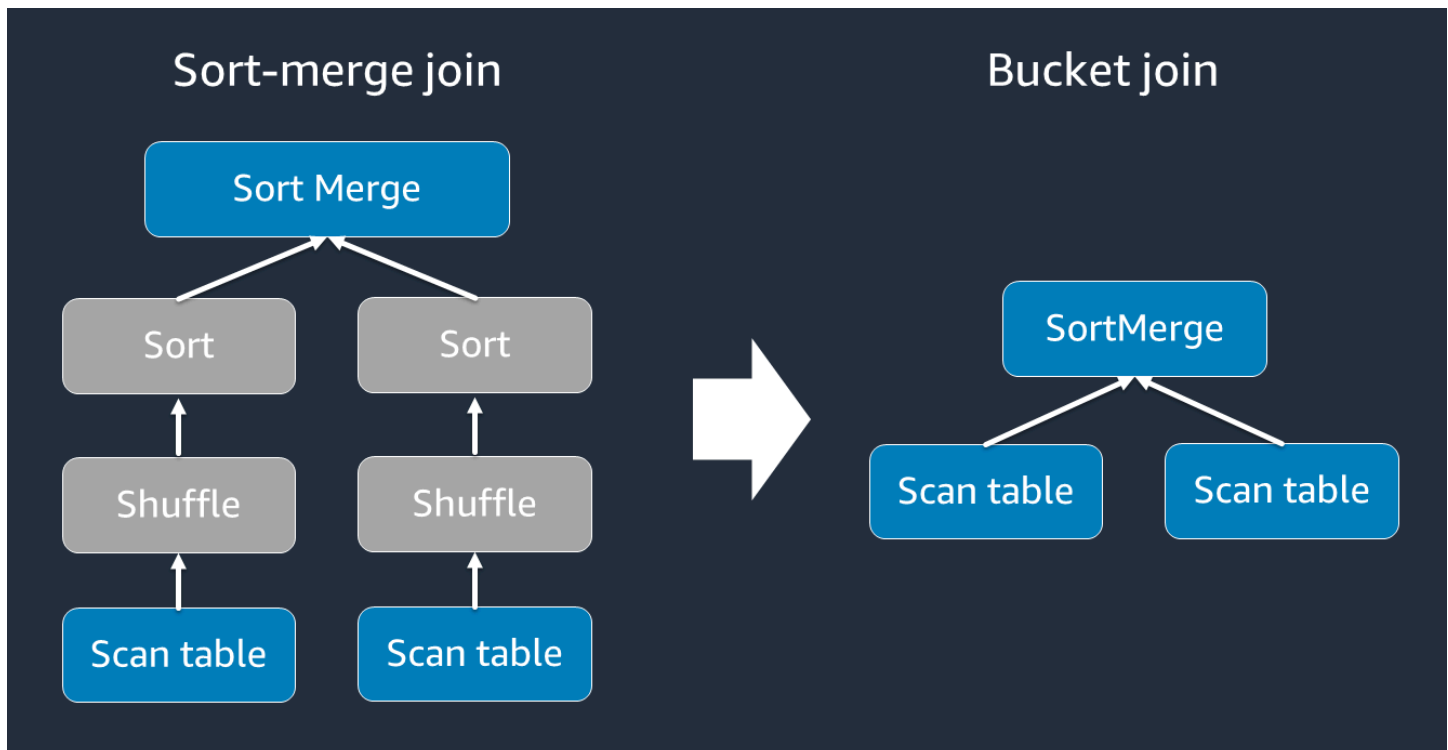
```
-- Join Hints for shuffle sort merge join
SELECT /*+ SHUFFLE_MERGE(t1) / FROM t1 INNER JOIN t2 ON t1.key = t2.key;
SELECT /*+ MERGEJOIN(t2) / FROM t1 INNER JOIN t2 ON t1.key = t2.key;
SELECT /*+ MERGE(t1) / FROM t1 INNER JOIN t2 ON t1.key = t2.key;

-- 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;
```

Utilisez le buketing

La jointure tri-fusion nécessite deux phases : mélanger et trier, puis fusionner. Ces deux phases peuvent surcharger l'exécuteur Spark OOM et entraîner des problèmes de performances lorsque certains exécuteurs fusionnent et que d'autres trient simultanément. Dans de tels cas, il peut être possible de se joindre efficacement en utilisant le [buketing](#). Le partitionnement prémélanger et triera au préalable vos entrées sur les touches de jointure, puis enregistrera les données triées dans une table intermédiaire. Le coût des étapes de brassage et de tri peut être réduit lorsque vous joignez de grandes tables en définissant à l'avance les tables intermédiaires triées.



Les tableaux à compartiments sont utiles dans les cas suivants :

- Des données fréquemment jointes via la même clé, telles que `account_id`
- Chargement de tables cumulatives quotidiennes, telles que les tables de base et de delta qui pourraient être regroupées dans une colonne commune

Vous pouvez créer une table à compartiments en utilisant le code suivant.

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

Répartition DataFrames sur les clés de jointure avant la jointure

Pour répartir les deux DataFrames sur les clés de jointure avant la jointure, utilisez les instructions suivantes.

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


Cela permettra de partitionner deux (toujours séparément) RDDs sur la clé de jointure avant de lancer la jointure. Si les deux RDDs sont partitionnés sur la même clé avec le même code de partitionnement, il est fort probable que les RDD enregistrements que vous projetez de joindre soient colocalisés sur le même worker avant d'être mélangés pour la jointure. Cela peut améliorer les performances en réduisant l'activité du réseau et le biais des données lors de la jointure.

Surmontez le biais des données

L'asymétrie des données est l'une des causes les plus fréquentes d'engorgement des tâches Spark. Cela se produit lorsque les données ne sont pas réparties uniformément entre les RDD partitions. Cela entraîne des tâches beaucoup plus longues pour cette partition que pour les autres, ce qui retarde le temps de traitement global de l'application.

Pour identifier le biais des données, évaluez les indicateurs suivants dans l'interface utilisateur de Spark :

- Dans l'onglet Stage de l'interface utilisateur de Spark, examinez la page Chronologie des événements. Vous pouvez voir une répartition inégale des tâches dans la capture d'écran suivante. Les tâches qui sont réparties de manière inégale ou dont l'exécution prend trop de temps peuvent indiquer une distorsion des données.



- Une autre page importante est celle des métriques récapitulatives, qui présente les statistiques des tâches Spark. La capture d'écran suivante montre les métriques avec des percentiles pour la durée, le temps GC, le déversement (mémoire), le déversement (disque), etc.

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

Lorsque les tâches sont réparties uniformément, vous verrez des chiffres similaires dans tous les percentiles. En cas de distorsion des données, vous verrez des valeurs très biaisées dans chaque percentile. Dans l'exemple, la durée de la tâche est inférieure à 13 secondes en min, 25e percentile, médian et 75e percentile. Bien que la tâche Max ait traité 100 fois plus de données que le 75e percentile, sa durée de 6,4 minutes est environ 30 fois plus longue. Cela signifie qu'au moins une tâche (ou jusqu'à 25 % des tâches) a pris beaucoup plus de temps que le reste des tâches.

Si vous constatez une distorsion des données, essayez ce qui suit :

- Si vous utilisez la AWS Glue version 3.0, activez l'exécution adaptative des requêtes en définissant `spark.sql.adaptive.enabled=true`. L'exécution adaptative des requêtes est activée par défaut dans la AWS Glue version 4.0.

Vous pouvez également utiliser l'exécution adaptative des requêtes pour le biais des données introduit par les jointures en définissant les paramètres connexes suivants :

- `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)

Pour plus d'informations, consultez la [documentation d'Apache Spark](#).

- Utilisez des clés avec une large plage de valeurs pour les clés de jointure. Dans une jointure aléatoire, les partitions sont déterminées pour chaque valeur de hachage d'une clé. Si la cardinalité d'une clé de jointure est trop faible, la fonction de hachage risque de mal répartir vos données entre les partitions. Par conséquent, si votre application et votre logique métier le permettent, envisagez d'utiliser une clé de cardinalité supérieure ou une clé composite.

```
# 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"])
```

Utiliser le cache

Lorsque vous utilisez le mode répétitif DataFrames, évitez tout remaniement ou calcul supplémentaire en utilisant `df.cache()` ou `df.persist()` en mettant en cache les résultats des calculs dans la mémoire et sur le disque de chaque exécuteur Spark. Spark prend également en charge RDDs la persistance sur le disque ou la réplication sur plusieurs nœuds ([niveau de stockage](#)).

Par exemple, vous pouvez les conserver DataFrames en ajoutant `df.persist()`. Lorsque le cache n'est plus nécessaire, vous pouvez l'utiliser `unpersist` pour supprimer les données mises en cache.

```
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()
```

Supprimer les actions Spark inutiles

Évitez d'exécuter des actions inutiles telles que `countshow`, ou `collect`. Comme indiqué dans la section [Sujets clés d'Apache Spark](#), Spark est paresseux. Chaque transformation RDD peut être recalculée chaque fois que vous exécutez une action dessus. Lorsque vous utilisez de nombreuses actions Spark, plusieurs accès à la source, des calculs de tâches et des exécutions aléatoires pour chaque action sont appelés.

Si vous n'avez pas besoin `collect()` d'effectuer d'autres actions dans votre environnement commercial, pensez à les supprimer.

Note

Évitez autant que possible d'utiliser `Spark collect()` dans des environnements commerciaux. L'`collect()` action renvoie tous les résultats d'un calcul effectué dans l'exécuteur Spark au pilote Spark, ce qui peut entraîner le renvoi d'une OOM erreur par le pilote Spark. Pour éviter toute OOM erreur, Spark définit `spark.driver.maxResultSize = 1GB` par défaut, ce qui limite la taille maximale des données renvoyées au pilote Spark à 1 Go.

Minimiser les frais de planification

Comme indiqué [dans les rubriques clés d'Apache Spark](#), le pilote Spark génère le plan d'exécution. Sur la base de ce plan, les tâches sont attribuées à l'exécuteur Spark pour un traitement distribué. Cependant, le pilote Spark peut devenir un goulot d'étranglement s'il AWS Glue Data Catalog contient un grand nombre de petits fichiers ou un grand nombre de partitions. Pour identifier les frais de planification élevés, évaluez les indicateurs suivants.


CloudWatch métriques

Vérifiez la CPUcharge et l'utilisation de la mémoire dans les situations suivantes :

- La CPUcharge du pilote Spark et l'utilisation de la mémoire sont enregistrées comme étant élevées. Normalement, le pilote Spark ne traite pas vos données, de sorte que la CPU charge

et l'utilisation de la mémoire n'augmentent pas. Toutefois, si la source de données Amazon S3 contient trop de petits fichiers, la liste de tous les objets S3 et la gestion d'un grand nombre de tâches peuvent entraîner une utilisation élevée des ressources.

- Il y a un long intervalle avant le début du traitement dans l'exécuteur Spark. Dans l'exemple de capture d'écran suivant, la CPU charge de l'exécuteur Spark est trop faible avant 10 h 57, même si le AWS Glue travail a débuté à 10 h 00. Cela indique que le pilote Spark met peut-être beaucoup de temps à générer un plan d'exécution. Dans cet exemple, récupérer le grand nombre de partitions du catalogue de données et répertorier le grand nombre de petits fichiers dans le pilote Spark prend du temps.



Interface utilisateur Spark

Dans l'onglet Job de l'interface utilisateur de Spark, vous pouvez voir l'heure de soumission. Dans l'exemple suivant, le pilote Spark a démarré job0 à 10:56:46, même si le job a débuté à 10:00:00.
AWS Glue

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

Vous pouvez également voir les tâches (pour toutes les étapes) : Réussité/Durée totale dans l'onglet Job. Dans ce cas, le nombre de tâches est enregistré sous la forme 58100. Comme expliqué dans la section Amazon S3 de la page des [tâches de parallélisation](#), le nombre de tâches correspond

approximativement au nombre d'objets S3. Cela signifie qu'il y a environ 58 100 objets dans Amazon S3.


Pour plus de détails sur cette tâche et son calendrier, consultez l'onglet Étape. Si vous observez un goulot d'étranglement avec le pilote Spark, envisagez les solutions suivantes :

- Lorsque Amazon S3 contient trop de fichiers, consultez les instructions relatives au parallélisme excessif dans la section Trop de partitions de la page des tâches de [parallélisation](#).
- Lorsque le nombre de partitions d'Amazon S3 est trop élevé, consultez les instructions relatives au partitionnement excessif figurant dans la section Trop de partitions Amazon S3 de la page [Réduire la quantité de données numérisées](#). Activez [les index de AWS Glue partition](#) s'il existe de nombreuses partitions afin de réduire le temps de latence lors de la récupération des métadonnées des partitions à partir du catalogue de données. Pour plus d'informations, voir [Améliorer les performances des requêtes à l'aide des index de AWS Glue partition](#).
- Si JDBC le nombre de partitions est trop élevé, réduisez la `hashpartition` valeur.
- Lorsque DynamoDB possède un trop grand nombre de partitions, réduisez la valeur `dynamodb.splits`
- Lorsque les tâches de streaming comportent trop de partitions, réduisez le nombre de partitions.

Optimisation des fonctions définies par l'utilisateur

Les fonctions définies par l'utilisateur (UDFs) et `RDD.map` IN PySpark dégradent souvent les performances de manière significative. Cela est dû à la surcharge requise pour représenter avec précision votre code Python dans l'implémentation Scala sous-jacente de Spark.

Le schéma suivant montre l'architecture des PySpark tâches. Lorsque vous l'utilisez PySpark, le pilote Spark utilise la bibliothèque Py4j pour appeler des méthodes Java depuis Python. Lorsque vous appelez Spark SQL ou des fonctions DataFrame intégrées, il y a peu de différence de performance entre Python et Scala, car les fonctions s'exécutent sur chaque exécuteur à JVM l'aide d'un plan d'exécution optimisé.



Si vous utilisez votre propre logique Python, telle que `usingmap/ mapPartitions/ udf`, la tâche s'exécutera dans un environnement d'exécution Python. La gestion de deux environnements entraîne des frais généraux. En outre, vos données en mémoire doivent être transformées pour être utilisées par les fonctions intégrées de l'environnement JVM d'exécution. Pickle est un format de sérialisation utilisé par défaut pour l'échange entre les environnements d'exécution et JVM Python. Cependant, le coût de cette sérialisation et de cette désérialisation étant très élevé, les UDFs écrits en Java ou en Scala sont plus rapides que Python. UDFs

Pour éviter les surcharges liées à la sérialisation et à la désérialisation PySpark, tenez compte des points suivants :

- Utilisez les SQL fonctions Spark intégrées : envisagez de remplacer votre propre fonction UDF ou votre fonction cartographique par Spark SQL ou des fonctions DataFrame intégrées. Lors de l'exécution de Spark SQL ou de fonctions DataFrame intégrées, il y a peu de différence de performance entre Python et Scala, car les tâches sont gérées par chaque exécuteur. JVM
- UDFs Implémenter en Scala ou Java — Envisagez d'utiliser un UDF fichier écrit en Java ou en Scala, car ils s'exécutent sur le. JVM
- Utiliser la technologie basée sur Apache Arrow UDFs pour les charges de travail vectorisées : pensez à utiliser la technologie basée sur Arrow. UDFs Cette fonctionnalité est également connue sous le nom de vectorisation UDF (PandasUDF). [Apache Arrow](#) est un format de données en mémoire indépendant du langage qui AWS Glue peut être utilisé pour transférer efficacement des données entre et JVM des processus Python. C'est actuellement le plus avantageux pour les utilisateurs de Python qui travaillent avec des pandas ou NumPy des données.

La flèche est un format colonnaire (vectorisé). Son utilisation n'est pas automatique et peut nécessiter quelques modifications mineures de la configuration ou du code pour en tirer pleinement parti et garantir la compatibilité. Pour plus de détails et pour connaître les limites, voir [Apache Arrow dans PySpark](#).

L'exemple suivant compare un incrémental de base UDF en Python standard, en tant que vectorisé et en UDF Spark. SQL

Python standard UDF

Le temps d'exemple est de 3,20 (sec).

Exemple de code

```
# 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()
```

Plan d'exécution

```
== 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)
```

Vectorisé UDF

Le temps d'exemple est de 0,59 (sec).

Le vectorisé UDF est 5 fois plus rapide que l'exemple précédentUDF. Vous pouvez voir ArrowEvalPython que cette application est vectorisée par Apache Arrow. Physical Plan Pour activer VectorizedUDF, vous devez le spécifier `spark.sql.execution.arrow.pyspark.enabled = true` dans votre code.

Exemple de code

```
# 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()
```

Plan d'exécution

```
== 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)
```

Étincelle SQL

Le temps d'exemple est de 0,087 (sec).

Spark SQL est beaucoup plus rapide que VectorizedUDF, car les tâches sont exécutées sur chaque exécuteur sans environnement JVM d'exécution Python. Si vous pouvez le remplacer par une fonction intégrée, nous vous recommandons de le faire. UDF

Exemple de code

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

Utiliser les pandas pour les mégadonnées

Si vous connaissez déjà les [pandas et que](#) vous souhaitez utiliser Spark pour le Big Data, vous pouvez utiliser les pandas API sur Spark. AWS Glue Les versions 4.0 et ultérieures le supportent. Pour commencer, vous pouvez utiliser le bloc-notes officiel [Quickstart : Pandas API on](#) Spark. Pour plus d'informations, consultez la [PySpark documentation](#).

Ressources

- [AWS Glue](#)
- [Réglage des performances](#) (Guide Spark SQL)
- [AWS Glue Atelier d'optimisation](#)

Historique du document

Le tableau suivant décrit les modifications importantes apportées à ce guide. Pour être averti des mises à jour à venir, abonnez-vous à un [fil RSS](#).

Modification	Description	Date
Publication initiale	—	2 janvier 2024

AWS Glossaire des directives prescriptives

Les termes suivants sont couramment utilisés dans les stratégies, les guides et les modèles fournis par les directives AWS prescriptives. Pour suggérer des entrées, veuillez utiliser le lien [Faire un commentaire](#) à la fin du glossaire.

Nombres

7 R

Sept politiques de migration courantes pour transférer des applications vers le cloud. Ces politiques s'appuient sur les 5 R identifiés par Gartner en 2011 et sont les suivantes :

- **Refactorisation/réarchitecture** : transférez une application et modifiez son architecture en tirant pleinement parti des fonctionnalités natives cloud pour améliorer l'agilité, les performances et la capacité de mise à l'échelle. Cela implique généralement le transfert du système d'exploitation et de la base de données. Exemple : migrez votre base de données Oracle sur site vers l'édition compatible avec Amazon Aurora PostgreSQL.
- **Replateformer (déplacer et remodeler)** : transférez une application vers le cloud et introduisez un certain niveau d'optimisation pour tirer parti des fonctionnalités du cloud. Exemple : migrez votre base de données Oracle sur site vers Amazon Relational Database Service (Amazon RDS) pour Oracle dans le AWS Cloud
- **Racheter (rachat)** : optez pour un autre produit, généralement en passant d'une licence traditionnelle à un modèle SaaS. Exemple : migrez votre système de gestion de la relation client (CRM) vers Salesforce.com.
- **Réhéberger (lift and shift)** : transférez une application vers le cloud sans apporter de modifications pour tirer parti des fonctionnalités du cloud. Exemple : migrez votre base de données Oracle sur site vers Oracle sur une instance EC2 dans le AWS Cloud
- **Relocaliser (lift and shift au niveau de l'hyperviseur)** : transférez l'infrastructure vers le cloud sans acheter de nouveau matériel, réécrire des applications ou modifier vos opérations existantes. Vous migrez des serveurs d'une plateforme sur site vers un service cloud pour la même plateforme. Exemple : migrer une Microsoft Hyper-V application vers AWS.
- **Retenir** : conservez les applications dans votre environnement source. Il peut s'agir d'applications nécessitant une refactorisation majeure, que vous souhaitez retarder, et d'applications existantes que vous souhaitez retenir, car rien ne justifie leur migration sur le plan commercial.

- Retirer : mettez hors service ou supprimez les applications dont vous n'avez plus besoin dans votre environnement source.

A

ABAC

Voir contrôle [d'accès basé sur les attributs](#).

services abstraits

Consultez la section [Services gérés](#).

ACIDE

Voir [atomicité, consistance, isolation, durabilité](#).

migration active-active

Méthode de migration de base de données dans laquelle la synchronisation des bases de données source et cible est maintenue (à l'aide d'un outil de réplication bidirectionnelle ou d'opérations d'écriture double), tandis que les deux bases de données gèrent les transactions provenant de la connexion d'applications pendant la migration. Cette méthode prend en charge la migration par petits lots contrôlés au lieu d'exiger un basculement ponctuel. Elle est plus flexible mais demande plus de travail qu'une migration [active-passive](#).

migration active-passive

Méthode de migration de base de données dans laquelle la synchronisation des bases de données source et cible est maintenue, mais seule la base de données source gère les transactions provenant de la connexion d'applications pendant que les données sont répliquées vers la base de données cible. La base de données cible n'accepte aucune transaction pendant la migration.

fonction d'agrégation

Fonction SQL qui agit sur un groupe de lignes et calcule une valeur de retour unique pour le groupe. Des exemples de fonctions d'agrégation incluent SUM et MAX.

AI

Voir [intelligence artificielle](#).

AIOps

Voir les [opérations d'intelligence artificielle](#).

anonymisation

Processus de suppression définitive d'informations personnelles dans un ensemble de données. L'anonymisation peut contribuer à protéger la vie privée. Les données anonymisées ne sont plus considérées comme des données personnelles.

anti-motif

Solution fréquemment utilisée pour un problème récurrent lorsque la solution est contre-productive, inefficace ou moins efficace qu'une solution alternative.

contrôle des applications

Une approche de sécurité qui permet d'utiliser uniquement des applications approuvées afin de protéger un système contre les logiciels malveillants.

portefeuille d'applications

Ensemble d'informations détaillées sur chaque application utilisée par une organisation, y compris le coût de génération et de maintenance de l'application, ainsi que sa valeur métier. Ces informations sont essentielles pour [le processus de découverte et d'analyse du portefeuille](#) et permettent d'identifier et de prioriser les applications à migrer, à moderniser et à optimiser.

intelligence artificielle (IA)

Domaine de l'informatique consacré à l'utilisation des technologies de calcul pour exécuter des fonctions cognitives généralement associées aux humains, telles que l'apprentissage, la résolution de problèmes et la reconnaissance de modèles. Pour plus d'informations, veuillez consulter [Qu'est-ce que l'intelligence artificielle ?](#)

opérations d'intelligence artificielle (AIOps)

Processus consistant à utiliser des techniques de machine learning pour résoudre les problèmes opérationnels, réduire les incidents opérationnels et les interventions humaines, mais aussi améliorer la qualité du service. Pour plus d'informations sur la façon dont les AIOps sont utilisées dans la stratégie de migration AWS, veuillez consulter le [guide d'intégration des opérations](#).

chiffrement asymétrique

Algorithme de chiffrement qui utilise une paire de clés, une clé publique pour le chiffrement et une clé privée pour le déchiffrement. Vous pouvez partager la clé publique, car elle n'est pas utilisée pour le déchiffrement, mais l'accès à la clé privée doit être très restreint.

atomicité, cohérence, isolement, durabilité (ACID)

Ensemble de propriétés logicielles garantissant la validité des données et la fiabilité opérationnelle d'une base de données, même en cas d'erreur, de panne de courant ou d'autres problèmes.

contrôle d'accès par attributs (ABAC)

Pratique qui consiste à créer des autorisations détaillées en fonction des attributs de l'utilisateur, tels que le service, le poste et le nom de l'équipe. Pour plus d'informations, consultez [ABAC pour AWS](#) dans la documentation AWS Identity and Access Management (IAM).

source de données faisant autorité

Emplacement où vous stockez la version principale des données, considérée comme la source d'information la plus fiable. Vous pouvez copier les données de la source de données officielle vers d'autres emplacements à des fins de traitement ou de modification des données, par exemple en les anonymisant, en les expurgant ou en les pseudonymisant.

Zone de disponibilité

Un emplacement distinct au sein d'une Région AWS réseau isolé des défaillances dans d'autres zones de disponibilité et fournissant une connectivité réseau peu coûteuse et à faible latence aux autres zones de disponibilité de la même région.

AWS Cadre d'adoption du cloud (AWS CAF)

Un cadre de directives et de meilleures pratiques visant AWS à aider les entreprises à élaborer un plan efficace pour réussir leur migration vers le cloud. AWS La CAF organise ses conseils en six domaines prioritaires appelés perspectives : les affaires, les personnes, la gouvernance, les plateformes, la sécurité et les opérations. Les perspectives d'entreprise, de personnes et de gouvernance mettent l'accent sur les compétences et les processus métier, tandis que les perspectives relatives à la plateforme, à la sécurité et aux opérations se concentrent sur les compétences et les processus techniques. Par exemple, la perspective liée aux personnes cible les parties prenantes qui s'occupent des ressources humaines (RH), des fonctions de dotation en personnel et de la gestion des personnes. Dans cette perspective, la AWS CAF fournit des conseils pour le développement du personnel, la formation et les communications afin de préparer

l'organisation à une adoption réussie du cloud. Pour plus d'informations, veuillez consulter le [site Web AWS CAF](#) et le [livre blanc AWS CAF](#).

AWS Cadre de qualification de la charge de travail (AWS WQF)

Outil qui évalue les charges de travail liées à la migration des bases de données, recommande des stratégies de migration et fournit des estimations de travail. AWS Le WQF est inclus avec AWS Schema Conversion Tool (AWS SCT). Il analyse les schémas de base de données et les objets de code, le code d'application, les dépendances et les caractéristiques de performance, et fournit des rapports d'évaluation.

B

mauvais bot

Un [bot](#) destiné à perturber ou à nuire à des individus ou à des organisations.

BCP

Consultez la section [Planification de la continuité des activités](#).

graphique de comportement

Vue unifiée et interactive des comportements des ressources et des interactions au fil du temps. Vous pouvez utiliser un graphique de comportement avec Amazon Detective pour examiner les tentatives de connexion infructueuses, les appels d'API suspects et les actions similaires. Pour plus d'informations, veuillez consulter [Data in a behavior graph](#) dans la documentation Detective.

système de poids fort

Système qui stocke d'abord l'octet le plus significatif. Voir aussi [endianité](#).

classification binaire

Processus qui prédit un résultat binaire (l'une des deux classes possibles). Par exemple, votre modèle de machine learning peut avoir besoin de prévoir des problèmes tels que « Cet e-mail est-il du spam ou non ? » ou « Ce produit est-il un livre ou une voiture ? ».

filtre de Bloom

Structure de données probabiliste et efficace en termes de mémoire qui est utilisée pour tester si un élément fait partie d'un ensemble.

déploiement bleu/vert

Stratégie de déploiement dans laquelle vous créez deux environnements distincts mais identiques. Vous exécutez la version actuelle de l'application dans un environnement (bleu) et la nouvelle version de l'application dans l'autre environnement (vert). Cette stratégie vous permet de revenir rapidement en arrière avec un impact minimal.

bot

Application logicielle qui exécute des tâches automatisées sur Internet et simule l'activité ou l'interaction humaine. Certains robots sont utiles ou bénéfiques, comme les robots d'exploration Web qui indexent des informations sur Internet. D'autres robots, connus sous le nom de mauvais robots, sont destinés à perturber ou à nuire à des individus ou à des organisations.

botnet

Réseaux de [robots](#) infectés par des [logiciels malveillants](#) et contrôlés par une seule entité, connue sous le nom d'herder ou d'opérateur de bots. Les botnets sont le mécanisme le plus connu pour faire évoluer les bots et leur impact.

branche

Zone contenue d'un référentiel de code. La première branche créée dans un référentiel est la branche principale. Vous pouvez créer une branche à partir d'une branche existante, puis développer des fonctionnalités ou corriger des bogues dans la nouvelle branche. Une branche que vous créez pour générer une fonctionnalité est communément appelée branche de fonctionnalités. Lorsque la fonctionnalité est prête à être publiée, vous fusionnez à nouveau la branche de fonctionnalités dans la branche principale. Pour plus d'informations, consultez [À propos des branches](#) (GitHub documentation).

accès par brise-vitre

Dans des circonstances exceptionnelles et par le biais d'un processus approuvé, c'est un moyen rapide pour un utilisateur d'accéder à un accès auquel Compte AWS il n'est généralement pas autorisé. Pour plus d'informations, consultez l'indicateur [Implementation break-glass procedures](#) dans le guide Well-Architected AWS .

stratégie existante (brownfield)

L'infrastructure existante de votre environnement. Lorsque vous adoptez une stratégie existante pour une architecture système, vous concevez l'architecture en fonction des contraintes des systèmes et de l'infrastructure actuels. Si vous étendez l'infrastructure existante, vous pouvez combiner des politiques brownfield (existantes) et [greenfield](#) (inédites).

cache de tampon

Zone de mémoire dans laquelle sont stockées les données les plus fréquemment consultées.

capacité métier

Ce que fait une entreprise pour générer de la valeur (par exemple, les ventes, le service client ou le marketing). Les architectures de microservices et les décisions de développement peuvent être dictées par les capacités métier. Pour plus d'informations, veuillez consulter la section [Organisation en fonction des capacités métier](#) du livre blanc [Exécution de microservices conteneurisés sur AWS](#).

planification de la continuité des activités (BCP)

Plan qui tient compte de l'impact potentiel d'un événement perturbateur, tel qu'une migration à grande échelle, sur les opérations, et qui permet à une entreprise de reprendre ses activités rapidement.

C

CAF

Voir le [cadre d'adoption du AWS cloud](#).

déploiement de Canary

Diffusion lente et progressive d'une version pour les utilisateurs finaux. Lorsque vous êtes sûr, vous déployez la nouvelle version et remplacez la version actuelle dans son intégralité.

CCoE

Voir [le Centre d'excellence du cloud](#).

CDC

Consultez la section [Capture des données de modification](#).

capture des données de modification (CDC)

Processus de suivi des modifications apportées à une source de données, telle qu'une table de base de données, et d'enregistrement des métadonnées relatives à ces modifications. Vous pouvez utiliser la CDC à diverses fins, telles que l'audit ou la réplication des modifications dans un système cible afin de maintenir la synchronisation.

ingénierie du chaos

Introduire intentionnellement des défaillances ou des événements perturbateurs pour tester la résilience d'un système. Vous pouvez utiliser [AWS Fault Injection Service \(AWS FIS\)](#) pour effectuer des expériences qui stressent vos AWS charges de travail et évaluer leur réponse.

CI/CD

Découvrez [l'intégration continue et la livraison continue](#).

classification

Processus de catégorisation qui permet de générer des prédictions. Les modèles de ML pour les problèmes de classification prédisent une valeur discrète. Les valeurs discrètes se distinguent toujours les unes des autres. Par exemple, un modèle peut avoir besoin d'évaluer la présence ou non d'une voiture sur une image.

chiffrement côté client

Chiffrement des données localement, avant que la cible ne les service AWS reçoive.

Centre d'excellence cloud (CCoE)

Une équipe multidisciplinaire qui dirige les efforts d'adoption du cloud au sein d'une organisation, notamment en développant les bonnes pratiques en matière de cloud, en mobilisant des ressources, en établissant des délais de migration et en guidant l'organisation dans le cadre de transformations à grande échelle. Pour plus d'informations, consultez les [articles du CCoE](#) sur le blog de stratégie AWS Cloud d'entreprise.

cloud computing

Technologie cloud généralement utilisée pour le stockage de données à distance et la gestion des appareils IoT. Le cloud computing est généralement associé à la technologie [informatique de pointe](#).

modèle d'exploitation du cloud

Dans une organisation informatique, modèle d'exploitation utilisé pour créer, faire évoluer et optimiser un ou plusieurs environnements cloud. Pour plus d'informations, consultez la section [Création de votre modèle d'exploitation cloud](#).

étapes d'adoption du cloud

Les quatre phases que les entreprises traversent généralement lorsqu'elles migrent vers AWS Cloud :

- **Projet** : exécution de quelques projets liés au cloud à des fins de preuve de concept et d'apprentissage
- **Base** : réaliser des investissements fondamentaux pour mettre à l'échelle l'adoption du cloud (par exemple, en créant une zone de destination, en définissant un CCoE ou en établissant un modèle opérationnel)
- **Migration** : migration d'applications individuelles
- **Réinvention** : optimisation des produits et services et innovation dans le cloud

Ces étapes ont été définies par Stephen Orban dans le billet de blog [The Journey Toward Cloud-First & the Stages of Adoption](#) publié sur le blog AWS Cloud Enterprise Strategy. Pour plus d'informations sur leur lien avec la stratégie de AWS migration, consultez le [guide de préparation à la migration](#).

CMDB

Voir base de [données de gestion de configuration](#).

référentiel de code

Emplacement où le code source et d'autres ressources, comme la documentation, les exemples et les scripts, sont stockés et mis à jour par le biais de processus de contrôle de version. Les référentiels cloud courants incluent GitHub ou AWS CodeCommit. Chaque version du code est appelée branche. Dans une structure de microservice, chaque référentiel est consacré à une seule fonctionnalité. Un seul pipeline CI/CD peut utiliser plusieurs référentiels.

cache passif

Cache tampon vide, mal rempli ou contenant des données obsolètes ou non pertinentes. Cela affecte les performances, car l'instance de base de données doit lire à partir de la mémoire principale ou du disque, ce qui est plus lent que la lecture à partir du cache tampon.

données gelées

Données rarement consultées et généralement historiques. Lorsque vous interrogez ce type de données, les requêtes lentes sont généralement acceptables. Le transfert de ces données vers des niveaux ou classes de stockage moins performants et moins coûteux peut réduire les coûts.

vision par ordinateur (CV)

Domaine de l'[IA](#) qui utilise l'apprentissage automatique pour analyser et extraire des informations à partir de formats visuels tels que des images numériques et des vidéos. Par exemple, AWS

Panorama propose des appareils qui ajoutent des CV aux réseaux de caméras locaux, et Amazon SageMaker fournit des algorithmes de traitement d'image pour les CV.

dérive de configuration

Pour une charge de travail, une modification de configuration par rapport à l'état attendu. Cela peut entraîner une non-conformité de la charge de travail, et cela est généralement progressif et involontaire.

base de données de gestion des configurations (CMDB)

Référentiel qui stocke et gère les informations relatives à une base de données et à son environnement informatique, y compris les composants matériels et logiciels ainsi que leurs configurations. Vous utilisez généralement les données d'une CMDB lors de la phase de découverte et d'analyse du portefeuille de la migration.

pack de conformité

Ensemble de AWS Config règles et d'actions correctives que vous pouvez assembler pour personnaliser vos contrôles de conformité et de sécurité. Vous pouvez déployer un pack de conformité en tant qu'entité unique dans une région Compte AWS et, ou au sein d'une organisation, à l'aide d'un modèle YAML. Pour plus d'informations, consultez la section [Packs de conformité](#) dans la AWS Config documentation.

intégration continue et livraison continue (CI/CD)

Processus d'automatisation des étapes source, de génération, de test, intermédiaire et de production du processus de publication du logiciel. CI/CD est communément décrit comme un pipeline. CI/CD peut vous aider à automatiser les processus, à améliorer la productivité, à améliorer la qualité du code et à accélérer les livraisons. Pour plus d'informations, veuillez consulter [Avantages de la livraison continue](#). CD peut également signifier déploiement continu. Pour plus d'informations, veuillez consulter [Livraison continue et déploiement continu](#).

CV

Voir [vision par ordinateur](#).

D

données au repos

Données stationnaires dans votre réseau, telles que les données stockées.

classification des données

Processus permettant d'identifier et de catégoriser les données de votre réseau en fonction de leur sévérité et de leur sensibilité. Il s'agit d'un élément essentiel de toute stratégie de gestion des risques de cybersécurité, car il vous aide à déterminer les contrôles de protection et de conservation appropriés pour les données. La classification des données est une composante du pilier de sécurité du AWS Well-Architected Framework. Pour plus d'informations, veuillez consulter [Classification des données](#).

dérive des données

Une variation significative entre les données de production et les données utilisées pour entraîner un modèle ML, ou une modification significative des données d'entrée au fil du temps. La dérive des données peut réduire la qualité, la précision et l'équité globales des prédictions des modèles ML.

données en transit

Données qui circulent activement sur votre réseau, par exemple entre les ressources du réseau.

maillage de données

Un cadre architectural qui fournit une propriété des données distribuée et décentralisée avec une gestion et une gouvernance centralisées.

minimisation des données

Le principe de collecte et de traitement des seules données strictement nécessaires. La pratique de la minimisation des données AWS Cloud peut réduire les risques liés à la confidentialité, les coûts et l'empreinte carbone de vos analyses.

périmètre de données

Ensemble de garde-fous préventifs dans votre AWS environnement qui permettent de garantir que seules les identités fiables accèdent aux ressources fiables des réseaux attendus. Pour plus d'informations, voir [Création d'un périmètre de données sur AWS](#).

prétraitement des données

Pour transformer les données brutes en un format facile à analyser par votre modèle de ML. Le prétraitement des données peut impliquer la suppression de certaines colonnes ou lignes et le traitement des valeurs manquantes, incohérentes ou en double.

provenance des données

Le processus de suivi de l'origine et de l'historique des données tout au long de leur cycle de vie, par exemple la manière dont les données ont été générées, transmises et stockées.

sujet des données

Personne dont les données sont collectées et traitées.

entrepôt des données

Un système de gestion des données qui prend en charge les informations commerciales, telles que les analyses. Les entrepôts de données contiennent généralement de grandes quantités de données historiques et sont généralement utilisés pour les requêtes et les analyses.

langage de définition de base de données (DDL)

Instructions ou commandes permettant de créer ou de modifier la structure des tables et des objets dans une base de données.

langage de manipulation de base de données (DML)

Instructions ou commandes permettant de modifier (insérer, mettre à jour et supprimer) des informations dans une base de données.

DDL

Voir [langage de définition de base](#) de données.

ensemble profond

Sert à combiner plusieurs modèles de deep learning à des fins de prédiction. Vous pouvez utiliser des ensembles profonds pour obtenir une prévision plus précise ou pour estimer l'incertitude des prédictions.

deep learning

Un sous-champ de ML qui utilise plusieurs couches de réseaux neuronaux artificiels pour identifier le mappage entre les données d'entrée et les variables cibles d'intérêt.

defense-in-depth

Approche de la sécurité de l'information dans laquelle une série de mécanismes et de contrôles de sécurité sont judicieusement répartis sur l'ensemble d'un réseau informatique afin de protéger la confidentialité, l'intégrité et la disponibilité du réseau et des données qu'il contient. Lorsque vous adoptez cette stratégie AWS, vous ajoutez plusieurs contrôles à différentes couches de

la AWS Organizations structure afin de sécuriser les ressources. Par exemple, une défense-in-depth approche peut combiner l'authentification multifactorielle, la segmentation du réseau et le chiffrement.

administrateur délégué

Dans AWS Organizations, un service compatible peut enregistrer un compte AWS membre pour administrer les comptes de l'organisation et gérer les autorisations pour ce service. Ce compte est appelé administrateur délégué pour ce service. Pour plus d'informations et une liste des services compatibles, veuillez consulter la rubrique [Services qui fonctionnent avec AWS Organizations](#) dans la documentation AWS Organizations .

déploiement

Processus de mise à disposition d'une application, de nouvelles fonctionnalités ou de corrections de code dans l'environnement cible. Le déploiement implique la mise en œuvre de modifications dans une base de code, puis la génération et l'exécution de cette base de code dans les environnements de l'application.

environnement de développement

Voir [environnement](#).

contrôle de détection

Contrôle de sécurité conçu pour détecter, journaliser et alerter après la survenue d'un événement. Ces contrôles constituent une deuxième ligne de défense et vous alertent en cas d'événements de sécurité qui ont contourné les contrôles préventifs en place. Pour plus d'informations, veuillez consulter la rubrique [Contrôles de détection](#) dans *Implementing security controls on AWS*.

cartographie de la chaîne de valeur du développement (DVSM)

Processus utilisé pour identifier et hiérarchiser les contraintes qui nuisent à la rapidité et à la qualité du cycle de vie du développement logiciel. DVSM étend le processus de cartographie de la chaîne de valeur initialement conçu pour les pratiques de production allégée. Il met l'accent sur les étapes et les équipes nécessaires pour créer et transférer de la valeur tout au long du processus de développement logiciel.

jumeau numérique

Représentation virtuelle d'un système réel, tel qu'un bâtiment, une usine, un équipement industriel ou une ligne de production. Les jumeaux numériques prennent en charge la maintenance prédictive, la surveillance à distance et l'optimisation de la production.

tableau des dimensions

Dans un [schéma en étoile](#), table plus petite contenant les attributs de données relatifs aux données quantitatives d'une table de faits. Les attributs des tables de dimensions sont généralement des champs de texte ou des nombres discrets qui se comportent comme du texte. Ces attributs sont couramment utilisés pour la contrainte des requêtes, le filtrage et l'étiquetage des ensembles de résultats.

catastrophe

Un événement qui empêche une charge de travail ou un système d'atteindre ses objectifs commerciaux sur son site de déploiement principal. Ces événements peuvent être des catastrophes naturelles, des défaillances techniques ou le résultat d'actions humaines, telles qu'une mauvaise configuration involontaire ou une attaque de logiciel malveillant.

reprise après sinistre (DR)

La stratégie et le processus que vous utilisez pour minimiser les temps d'arrêt et les pertes de données causés par un [sinistre](#). Pour plus d'informations, consultez [Disaster Recovery of Workloads on AWS : Recovery in the Cloud in the AWS Well-Architected Framework](#).

DML

Voir [langage de manipulation de base](#) de données.

conception axée sur le domaine

Approche visant à développer un système logiciel complexe en connectant ses composants à des domaines évolutifs, ou objectifs métier essentiels, que sert chaque composant. Ce concept a été introduit par Eric Evans dans son ouvrage *Domain-Driven Design: Tackling Complexity in the Heart of Software* (Boston : Addison-Wesley Professional, 2003). Pour plus d'informations sur l'utilisation du design piloté par domaine avec le modèle de figuier étrangleur, veuillez consulter [Modernizing legacy Microsoft ASP.NET \(ASMX\) web services incrementally by using containers and Amazon API Gateway](#).

DR

Consultez la section [Reprise après sinistre](#).

détection de dérive

Suivi des écarts par rapport à une configuration de référence. Par exemple, vous pouvez l'utiliser AWS CloudFormation pour [détecter la dérive des ressources du système](#) ou AWS Control Tower

pour [détecter les modifications de votre zone d'atterrissage](#) susceptibles d'affecter le respect des exigences de gouvernance.

DVSM

Voir la [cartographie de la chaîne de valeur du développement](#).

E

EDA

Voir [analyse exploratoire des données](#).

informatique de périphérie

Technologie qui augmente la puissance de calcul des appareils intelligents en périphérie d'un réseau IoT. Comparé au [cloud computing, l'informatique](#) de pointe peut réduire la latence des communications et améliorer le temps de réponse.

chiffrement

Processus informatique qui transforme des données en texte clair, lisibles par l'homme, en texte chiffré.

clé de chiffrement

Chaîne cryptographique de bits aléatoires générée par un algorithme cryptographique. La longueur des clés peut varier, et chaque clé est conçue pour être imprévisible et unique.

endianisme

Ordre selon lequel les octets sont stockés dans la mémoire de l'ordinateur. Les systèmes de poids fort stockent d'abord l'octet le plus significatif. Les systèmes de poids faible stockent d'abord l'octet le moins significatif.

point de terminaison

Voir [point de terminaison de service](#).

service de point de terminaison

Service que vous pouvez héberger sur un cloud privé virtuel (VPC) pour le partager avec d'autres utilisateurs. Vous pouvez créer un service de point de terminaison avec AWS PrivateLink et accorder des autorisations à d'autres principaux Comptes AWS ou à AWS Identity and Access Management (IAM) principaux. Ces comptes ou principaux peuvent se connecter à votre

service de point de terminaison de manière privée en créant des points de terminaison d'un VPC d'interface. Pour plus d'informations, veuillez consulter [Création d'un service de point de terminaison](#) dans la documentation Amazon Virtual Private Cloud (Amazon VPC).

planification des ressources d'entreprise (ERP)

Système qui automatise et gère les principaux processus métier (tels que la comptabilité, le [MES](#) et la gestion de projet) pour une entreprise.

chiffrement d'enveloppe

Processus de chiffrement d'une clé de chiffrement à l'aide d'une autre clé de chiffrement. Pour plus d'informations, consultez la section [Chiffrement des enveloppes](#) dans la documentation AWS Key Management Service (AWS KMS).

environnement

Instance d'une application en cours d'exécution. Les types d'environnement les plus courants dans le cloud computing sont les suivants :

- Environnement de développement : instance d'une application en cours d'exécution à laquelle seule l'équipe principale chargée de la maintenance de l'application peut accéder. Les environnements de développement sont utilisés pour tester les modifications avant de les promouvoir dans les environnements supérieurs. Ce type d'environnement est parfois appelé environnement de test.
- Environnements inférieurs : tous les environnements de développement d'une application, tels que ceux utilisés pour les générations et les tests initiaux.
- Environnement de production : instance d'une application en cours d'exécution à laquelle les utilisateurs finaux peuvent accéder. Dans un pipeline CI/CD, l'environnement de production est le dernier environnement de déploiement.
- Environnements supérieurs : tous les environnements accessibles aux utilisateurs autres que l'équipe de développement principale. Ils peuvent inclure un environnement de production, des environnements de préproduction et des environnements pour les tests d'acceptation par les utilisateurs.

épopée

Dans les méthodologies agiles, catégories fonctionnelles qui aident à organiser et à prioriser votre travail. Les épopées fournissent une description détaillée des exigences et des tâches d'implémentation. Par exemple, les points forts de la AWS CAF en matière de sécurité incluent la gestion des identités et des accès, les contrôles de détection, la sécurité des infrastructures,

la protection des données et la réponse aux incidents. Pour plus d'informations sur les épépées dans la stratégie de migration AWS , veuillez consulter le [guide d'implémentation du programme](#).

ERP

Voir [Planification des ressources d'entreprise](#).

analyse exploratoire des données (EDA)

Processus d'analyse d'un jeu de données pour comprendre ses principales caractéristiques. Vous collectez ou agrégez des données, puis vous effectuez des enquêtes initiales pour trouver des modèles, détecter des anomalies et vérifier les hypothèses. L'EDA est réalisée en calculant des statistiques récapitulatives et en créant des visualisations de données.

F

tableau des faits

La table centrale dans un [schéma en étoile](#). Il stocke des données quantitatives sur les opérations commerciales. Généralement, une table de faits contient deux types de colonnes : celles qui contiennent des mesures et celles qui contiennent une clé étrangère pour une table de dimensions.

échouer rapidement

Une philosophie qui utilise des tests fréquents et progressifs pour réduire le cycle de vie du développement. C'est un élément essentiel d'une approche agile.

limite d'isolation des défauts

Dans le AWS Cloud, une limite telle qu'une zone de disponibilité Région AWS, un plan de contrôle ou un plan de données qui limite l'effet d'une panne et contribue à améliorer la résilience des charges de travail. Pour plus d'informations, consultez la section [Limites d'isolation des AWS pannes](#).

branche de fonctionnalités

Voir [la succursale](#).

fonctionnalités

Les données d'entrée que vous utilisez pour faire une prédiction. Par exemple, dans un contexte de fabrication, les fonctionnalités peuvent être des images capturées périodiquement à partir de la ligne de fabrication.

importance des fonctionnalités

Le niveau d'importance d'une fonctionnalité pour les prédictions d'un modèle. Il s'exprime généralement sous la forme d'un score numérique qui peut être calculé à l'aide de différentes techniques, telles que la méthode Shapley Additive Explanations (SHAP) et les gradients intégrés. Pour plus d'informations, voir [Interprétabilité du modèle d'apprentissage automatique avec :AWS](#).

transformation de fonctionnalité

Optimiser les données pour le processus de ML, notamment en enrichissant les données avec des sources supplémentaires, en mettant à l'échelle les valeurs ou en extrayant plusieurs ensembles d'informations à partir d'un seul champ de données. Cela permet au modèle de ML de tirer parti des données. Par exemple, si vous décomposez la date « 2021-05-27 00:15:37 » en « 2021 », « mai », « jeudi » et « 15 », vous pouvez aider l'algorithme d'apprentissage à apprendre des modèles nuancés associés à différents composants de données.

FGAC

Découvrez le [contrôle d'accès détaillé](#).

contrôle d'accès détaillé (FGAC)

Utilisation de plusieurs conditions pour autoriser ou refuser une demande d'accès.

migration instantanée (flash-cut)

Méthode de migration de base de données qui utilise la réplication continue des données via la [capture des données de modification](#) afin de migrer les données dans les plus brefs délais, au lieu d'utiliser une approche progressive. L'objectif est de réduire au maximum les temps d'arrêt.

G

blocage géographique

Voir les [restrictions géographiques](#).

restrictions géographiques (blocage géographique)

Sur Amazon CloudFront, option permettant d'empêcher les utilisateurs de certains pays d'accéder aux distributions de contenu. Vous pouvez utiliser une liste d'autorisation ou une liste de blocage pour spécifier les pays approuvés et interdits. Pour plus d'informations, consultez [la section Restreindre la distribution géographique de votre contenu](#) dans la CloudFront documentation.

Flux de travail Gitflow

Approche dans laquelle les environnements inférieurs et supérieurs utilisent différentes branches dans un référentiel de code source. Le flux de travail Gitflow est considéré comme existant, et le [flux de travail basé sur les troncs](#) est l'approche moderne préférée.

stratégie inédite

L'absence d'infrastructures existantes dans un nouvel environnement. Lorsque vous adoptez une stratégie inédite pour une architecture système, vous pouvez sélectionner toutes les nouvelles technologies sans restriction de compatibilité avec l'infrastructure existante, également appelée [brownfield](#). Si vous étendez l'infrastructure existante, vous pouvez combiner des politiques brownfield (existantes) et greenfield (inédites).

barrière de protection

Règle de haut niveau qui permet de régir les ressources, les politiques et la conformité au sein des unités d'organisation (UO). Les barrières de protection préventives appliquent des politiques pour garantir l'alignement sur les normes de conformité. Elles sont mises en œuvre à l'aide de politiques de contrôle des services et de limites des autorisations IAM. Les barrières de protection de détection détectent les violations des politiques et les problèmes de conformité, et génèrent des alertes pour y remédier. Ils sont implémentés à l'aide d'Amazon AWS Config AWS Security Hub GuardDuty AWS Trusted Advisor, d'Amazon Inspector et de AWS Lambda contrôles personnalisés.

H

HA

Découvrez [la haute disponibilité](#).

migration de base de données hétérogène

Migration de votre base de données source vers une base de données cible qui utilise un moteur de base de données différent (par exemple, Oracle vers Amazon Aurora). La migration hétérogène fait généralement partie d'un effort de réarchitecture, et la conversion du schéma peut s'avérer une tâche complexe. [AWS propose AWS SCT](#) qui facilite les conversions de schémas.

haute disponibilité (HA)

Capacité d'une charge de travail à fonctionner en continu, sans intervention, en cas de difficultés ou de catastrophes. Les systèmes HA sont conçus pour basculer automatiquement, fournir

constamment des performances de haute qualité et gérer différentes charges et défaillances avec un impact minimal sur les performances.

modernisation de l'historien

Approche utilisée pour moderniser et mettre à niveau les systèmes de technologie opérationnelle (OT) afin de mieux répondre aux besoins de l'industrie manufacturière. Un historien est un type de base de données utilisé pour collecter et stocker des données provenant de diverses sources dans une usine.

migration de base de données homogène

Migration de votre base de données source vers une base de données cible qui partage le même moteur de base de données (par exemple, Microsoft SQL Server vers Amazon RDS for SQL Server). La migration homogène s'inscrit généralement dans le cadre d'un effort de réhébergement ou de replateforme. Vous pouvez utiliser les utilitaires de base de données natifs pour migrer le schéma.

données chaudes

Données fréquemment consultées, telles que les données en temps réel ou les données transactionnelles récentes. Ces données nécessitent généralement un niveau ou une classe de stockage à hautes performances pour fournir des réponses rapides aux requêtes.

correctif

Solution d'urgence à un problème critique dans un environnement de production. En raison de son urgence, un correctif est généralement créé en dehors du flux de travail de DevOps publication habituel.

période de soins intensifs

Immédiatement après le basculement, période pendant laquelle une équipe de migration gère et surveille les applications migrées dans le cloud afin de résoudre les problèmes éventuels. En règle générale, cette période dure de 1 à 4 jours. À la fin de la période de soins intensifs, l'équipe de migration transfère généralement la responsabilité des applications à l'équipe des opérations cloud.

I

IaC

Considérez [l'infrastructure comme un code](#).

politique basée sur l'identité

Politique attachée à un ou plusieurs principaux IAM qui définit leurs autorisations au sein de l'AWS Cloud environnement.

application inactive

Application dont l'utilisation moyenne du processeur et de la mémoire se situe entre 5 et 20 % sur une période de 90 jours. Dans un projet de migration, il est courant de retirer ces applications ou de les retenir sur site.

IIoT

Voir [Internet industriel des objets](#).

infrastructure immuable

Modèle qui déploie une nouvelle infrastructure pour les charges de travail de production au lieu de mettre à jour, d'appliquer des correctifs ou de modifier l'infrastructure existante. Les infrastructures immuables sont intrinsèquement plus cohérentes, fiables et prévisibles que les infrastructures [mutables](#). Pour plus d'informations, consultez les meilleures pratiques de [déploiement à l'aide d'une infrastructure immuable](#) dans le AWS Well-Architected Framework.

VPC entrant (d'entrée)

Dans une architecture AWS multi-comptes, un VPC qui accepte, inspecte et achemine les connexions réseau depuis l'extérieur d'une application. L'[architecture de référence de sécuritéAWS](#) recommande de configurer votre compte réseau avec des VPC entrants, sortants et d'inspection afin de protéger l'interface bidirectionnelle entre votre application et Internet en général.

migration incrémentielle

Stratégie de basculement dans le cadre de laquelle vous migrez votre application par petites parties au lieu d'effectuer un basculement complet unique. Par exemple, il se peut que vous ne transfériez que quelques microservices ou utilisateurs vers le nouveau système dans un

I

premier temps. Après avoir vérifié que tout fonctionne correctement, vous pouvez transférer progressivement des microservices ou des utilisateurs supplémentaires jusqu'à ce que vous puissiez mettre hors service votre système hérité. Cette stratégie réduit les risques associés aux migrations de grande ampleur.

Industry 4.0

Terme introduit par [Klaus Schwab](#) en 2016 pour désigner la modernisation des processus de fabrication grâce aux avancées en matière de connectivité, de données en temps réel, d'automatisation, d'analyse et d'IA/ML.

infrastructure

Ensemble des ressources et des actifs contenus dans l'environnement d'une application.

infrastructure en tant que code (IaC)

Processus de mise en service et de gestion de l'infrastructure d'une application via un ensemble de fichiers de configuration. IaC est conçue pour vous aider à centraliser la gestion de l'infrastructure, à normaliser les ressources et à mettre à l'échelle rapidement afin que les nouveaux environnements soient reproductibles, fiables et cohérents.

internet industriel des objets (IIoT)

L'utilisation de capteurs et d'appareils connectés à Internet dans les secteurs industriels tels que la fabrication, l'énergie, l'automobile, les soins de santé, les sciences de la vie et l'agriculture. Pour plus d'informations, veuillez consulter [Building an industrial Internet of Things \(IIoT\) digital transformation strategy](#).

VPC d'inspection

Dans une architecture AWS multi-comptes, un VPC centralisé qui gère les inspections du trafic réseau entre les VPC (identiques ou Régions AWS différents), Internet et les réseaux sur site. L'[architecture de référence de sécurité AWS](#) recommande de configurer votre compte réseau avec des VPC entrants, sortants et d'inspection afin de protéger l'interface bidirectionnelle entre votre application et Internet en général.

Internet des objets (IoT)

Réseau d'objets physiques connectés dotés de capteurs ou de processeurs intégrés qui communiquent avec d'autres appareils et systèmes via Internet ou via un réseau de communication local. Pour plus d'informations, veuillez consulter la section [Qu'est-ce que l'IoT ?](#).

interprétabilité

Caractéristique d'un modèle de machine learning qui décrit dans quelle mesure un être humain peut comprendre comment les prédictions du modèle dépendent de ses entrées. Pour plus d'informations, veuillez consulter [Machine learning model interpretability with AWS](#).

IoT

Voir [Internet des objets](#).

Bibliothèque d'informations informatiques (ITIL)

Ensemble de bonnes pratiques pour proposer des services informatiques et les aligner sur les exigences métier. L'ITIL constitue la base de l'ITSM.

gestion des services informatiques (ITSM)

Activités associées à la conception, à la mise en œuvre, à la gestion et à la prise en charge de services informatiques d'une organisation. Pour plus d'informations sur l'intégration des opérations cloud aux outils ITSM, veuillez consulter le [guide d'intégration des opérations](#).

ITIL

Consultez la [bibliothèque d'informations informatiques](#).

ITSM

Consultez la section [Gestion des services informatiques](#).

L

contrôle d'accès basé sur des étiquettes (LBAC)

Une implémentation du contrôle d'accès obligatoire (MAC) dans laquelle une valeur d'étiquette de sécurité est explicitement attribuée aux utilisateurs et aux données elles-mêmes. L'intersection entre l'étiquette de sécurité utilisateur et l'étiquette de sécurité des données détermine les lignes et les colonnes visibles par l'utilisateur.

zone de destination

Une zone d'atterrissage est un AWS environnement multi-comptes bien conçu, évolutif et sécurisé. Il s'agit d'un point de départ à partir duquel vos entreprises peuvent rapidement lancer et déployer des charges de travail et des applications en toute confiance dans leur environnement

de sécurité et d'infrastructure. Pour plus d'informations sur les zones de destination, veuillez consulter [Setting up a secure and scalable multi-account AWS environment](#).

migration de grande envergure

Migration de 300 serveurs ou plus.

LBAC

Voir contrôle d'[accès basé sur des étiquettes](#).

principe de moindre privilège

Bonne pratique de sécurité qui consiste à accorder les autorisations minimales nécessaires à l'exécution d'une tâche. Pour plus d'informations, veuillez consulter la rubrique [Accorder les autorisations de moindre privilège](#) dans la documentation IAM.

lift and shift

Voir [7 Rs](#).

système de poids faible

Système qui stocke d'abord l'octet le moins significatif. Voir aussi [endianité](#).

environnements inférieurs

Voir [environnement](#).

M

machine learning (ML)

Type d'intelligence artificielle qui utilise des algorithmes et des techniques pour la reconnaissance et l'apprentissage de modèles. Le ML analyse et apprend à partir de données enregistrées, telles que les données de l'Internet des objets (IoT), pour générer un modèle statistique basé sur des modèles. Pour plus d'informations, veuillez consulter [Machine Learning](#).

branche principale

Voir [la succursale](#).

malware

Logiciel conçu pour compromettre la sécurité ou la confidentialité de l'ordinateur. Les logiciels malveillants peuvent perturber les systèmes informatiques, divulguer des informations sensibles

ou obtenir un accès non autorisé. Parmi les malwares, on peut citer les virus, les vers, les rançongiciels, les chevaux de Troie, les logiciels espions et les enregistreurs de frappe.

services gérés

services AWS qui AWS gère la couche d'infrastructure, le système d'exploitation et les plateformes, et vous accédez aux points de terminaison pour stocker et récupérer des données. Amazon Simple Storage Service (Amazon S3) et Amazon DynamoDB sont des exemples de services gérés. Ils sont également connus sous le nom de services abstraits.

système d'exécution de la fabrication (MES)

Un système logiciel pour le suivi, la surveillance, la documentation et le contrôle des processus de production qui convertissent les matières premières en produits finis dans l'atelier.

MAP

Voir [Migration Acceleration Program](#).

mécanisme

Processus complet au cours duquel vous créez un outil, favorisez son adoption, puis inspectez les résultats afin de procéder aux ajustements nécessaires. Un mécanisme est un cycle qui se renforce et s'améliore lorsqu'il fonctionne. Pour plus d'informations, voir [Création de mécanismes](#) dans le cadre AWS Well-Architected.

compte membre

Tous, à l'exception des Comptes AWS exception du compte de gestion, qui font partie d'une organisation dans AWS Organizations. Un compte ne peut être membre que d'une seule organisation à la fois.

MAILLES

Voir le [système d'exécution de la fabrication](#).

Transport télémétrique en file d'attente de messages (MQTT)

[Protocole de communication léger machine-to-machine \(M2M\), basé sur le modèle de publication/d'abonnement, pour les appareils IoT aux ressources limitées.](#)

microservice

Petit service indépendant qui communique via des API bien définies et qui est généralement détenu par de petites équipes autonomes. Par exemple, un système d'assurance peut inclure des microservices qui mappent à des capacités métier, telles que les ventes ou le marketing, ou

à des sous-domaines, tels que les achats, les réclamations ou l'analytique. Les avantages des microservices incluent l'agilité, la flexibilité de la mise à l'échelle, la facilité de déploiement, la réutilisation du code et la résilience. Pour plus d'informations, consultez la section [Intégration de microservices à l'aide de services AWS sans serveur](#).

architecture de microservices

Approche de création d'une application avec des composants indépendants qui exécutent chaque processus d'application en tant que microservice. Ces microservices communiquent via une interface bien définie à l'aide d'API légères. Chaque microservice de cette architecture peut être mis à jour, déployé et mis à l'échelle pour répondre à la demande de fonctions spécifiques d'une application. Pour plus d'informations, consultez la section [Implémentation de microservices sur AWS](#).

Programme d'accélération des migrations (MAP)

Un AWS programme qui fournit un support de conseil, des formations et des services pour aider les entreprises à établir une base opérationnelle solide pour passer au cloud, et pour aider à compenser le coût initial des migrations. MAP inclut une méthodologie de migration pour exécuter les migrations héritées de manière méthodique, ainsi qu'un ensemble d'outils pour automatiser et accélérer les scénarios de migration courants.

migration à grande échelle

Processus consistant à transférer la majeure partie du portefeuille d'applications vers le cloud par vagues, un plus grand nombre d'applications étant déplacées plus rapidement à chaque vague. Cette phase utilise les bonnes pratiques et les enseignements tirés des phases précédentes pour implémenter une usine de migration d'équipes, d'outils et de processus en vue de rationaliser la migration des charges de travail grâce à l'automatisation et à la livraison agile. Il s'agit de la troisième phase de la [stratégie de migration AWS](#).

usine de migration

Équipes interfonctionnelles qui rationalisent la migration des charges de travail grâce à des approches automatisées et agiles. Les équipes de Migration Factory comprennent généralement les opérations, les analystes commerciaux et les propriétaires, les ingénieurs de migration, les développeurs et les DevOps professionnels travaillant dans le cadre de sprints. Entre 20 et 50 % du portefeuille d'applications d'entreprise est constitué de modèles répétés qui peuvent être optimisés par une approche d'usine. Pour plus d'informations, veuillez consulter la rubrique [discussion of migration factories](#) et le [guide Cloud Migration Factory](#) dans cet ensemble de contenus.

métadonnées de migration

Informations relatives à l'application et au serveur nécessaires pour finaliser la migration.

Chaque modèle de migration nécessite un ensemble de métadonnées de migration différent. Les exemples de métadonnées de migration incluent le sous-réseau cible, le groupe de sécurité et le AWS compte.

modèle de migration

Tâche de migration reproductible qui détaille la stratégie de migration, la destination de la migration et l'application ou le service de migration utilisé. Exemple : réorganisez la migration vers Amazon EC2 AWS avec le service de migration d'applications.

Évaluation du portefeuille de migration (MPA)

Outil en ligne qui fournit des informations pour valider l'analyse de rentabilisation en faveur de la migration vers le. AWS Cloud La MPA propose une évaluation détaillée du portefeuille (dimensionnement approprié des serveurs, tarification, comparaison du coût total de possession, analyse des coûts de migration), ainsi que la planification de la migration (analyse et collecte des données d'applications, regroupement des applications, priorisation des migrations et planification des vagues). L'[outil MPA](#) (connexion requise) est disponible gratuitement pour tous les AWS consultants et consultants APN Partner.

Évaluation de la préparation à la migration (MRA)

Processus qui consiste à obtenir des informations sur l'état de préparation d'une organisation au cloud, à identifier les forces et les faiblesses et à élaborer un plan d'action pour combler les lacunes identifiées, à l'aide du AWS CAF. Pour plus d'informations, veuillez consulter le [guide de préparation à la migration](#). La MRA est la première phase de la [stratégie de migration AWS](#).

stratégie de migration

L'approche utilisée pour migrer une charge de travail vers le AWS Cloud. Pour plus d'informations, reportez-vous aux [7 R](#) de ce glossaire et à [Mobiliser votre organisation pour accélérer les migrations à grande échelle](#).

ML

Voir [apprentissage automatique](#).

modernisation

Transformation d'une application obsolète (héritée ou monolithique) et de son infrastructure en un système agile, élastique et hautement disponible dans le cloud afin de réduire les coûts, de

gagner en efficacité et de tirer parti des innovations. Pour plus d'informations, consultez [la section Stratégie de modernisation des applications dans le AWS Cloud](#).

évaluation de la préparation à la modernisation

Évaluation qui permet de déterminer si les applications d'une organisation sont prêtes à être modernisées, d'identifier les avantages, les risques et les dépendances, et qui détermine dans quelle mesure l'organisation peut prendre en charge l'état futur de ces applications. Le résultat de l'évaluation est un plan de l'architecture cible, une feuille de route détaillant les phases de développement et les étapes du processus de modernisation, ainsi qu'un plan d'action pour combler les lacunes identifiées. Pour plus d'informations, consultez la section [Évaluation de l'état de préparation à la modernisation des applications dans le AWS Cloud](#).

applications monolithiques (monolithes)

Applications qui s'exécutent en tant que service unique avec des processus étroitement couplés. Les applications monolithiques ont plusieurs inconvénients. Si une fonctionnalité de l'application connaît un pic de demande, l'architecture entière doit être mise à l'échelle. L'ajout ou l'amélioration des fonctionnalités d'une application monolithique devient également plus complexe lorsque la base de code s'élargit. Pour résoudre ces problèmes, vous pouvez utiliser une architecture de microservices. Pour plus d'informations, veuillez consulter [Decomposing monoliths into microservices](#).

MPA

Voir [Évaluation du portefeuille de migration](#).

MQTT

Voir [Message Queuing Telemetry Transport](#).

classification multi-classes

Processus qui permet de générer des prédictions pour plusieurs classes (prédiction d'un résultat parmi plus de deux). Par exemple, un modèle de ML peut demander « Ce produit est-il un livre, une voiture ou un téléphone ? » ou « Quelle catégorie de produits intéresse le plus ce client ? ».

infrastructure mutable

Modèle qui met à jour et modifie l'infrastructure existante pour les charges de travail de production. Pour améliorer la cohérence, la fiabilité et la prévisibilité, le AWS Well-Architected Framework recommande l'utilisation [d'une infrastructure immuable comme](#) meilleure pratique.

O

OAC

Voir [Contrôle d'accès à l'origine](#).

OAI

Voir [l'identité d'accès à l'origine](#).

OCM

Voir [gestion du changement organisationnel](#).

migration hors ligne

Méthode de migration dans laquelle la charge de travail source est supprimée au cours du processus de migration. Cette méthode implique un temps d'arrêt prolongé et est généralement utilisée pour de petites charges de travail non critiques.

OI

Consultez la section [Intégration des opérations](#).

OLA

Voir l'accord [au niveau opérationnel](#).

migration en ligne

Méthode de migration dans laquelle la charge de travail source est copiée sur le système cible sans être mise hors ligne. Les applications connectées à la charge de travail peuvent continuer à fonctionner pendant la migration. Cette méthode implique un temps d'arrêt nul ou minimal et est généralement utilisée pour les charges de travail de production critiques.

OPC-UA

Voir [Open Process Communications - Architecture unifiée](#).

Communications par processus ouvert - Architecture unifiée (OPC-UA)

Un protocole de communication machine-to-machine (M2M) pour l'automatisation industrielle. L'OPC-UA fournit une norme d'interopérabilité avec des schémas de cryptage, d'authentification et d'autorisation des données.

accord au niveau opérationnel (OLA)

Accord qui précise ce que les groupes informatiques fonctionnels s'engagent à fournir les uns aux autres, afin de prendre en charge un contrat de niveau de service (SLA).

examen de l'état de préparation opérationnelle (ORR)

Une liste de questions et de bonnes pratiques associées qui vous aident à comprendre, évaluer, prévenir ou réduire l'ampleur des incidents et des défaillances possibles. Pour plus d'informations, voir [Operational Readiness Reviews \(ORR\)](#) dans le AWS Well-Architected Framework.

technologie opérationnelle (OT)

Systèmes matériels et logiciels qui fonctionnent avec l'environnement physique pour contrôler les opérations, les équipements et les infrastructures industriels. Dans le secteur manufacturier, l'intégration des systèmes OT et des technologies de l'information (IT) est au cœur des transformations de [l'industrie 4.0](#).

intégration des opérations (OI)

Processus de modernisation des opérations dans le cloud, qui implique la planification de la préparation, l'automatisation et l'intégration. Pour en savoir plus, veuillez consulter le [guide d'intégration des opérations](#).

journal de suivi d'organisation

Un parcours créé par AWS CloudTrail qui enregistre tous les événements pour tous les membres Comptes AWS d'une organisation dans AWS Organizations. Ce journal de suivi est créé dans chaque Compte AWS qui fait partie de l'organisation et suit l'activité de chaque compte. Pour plus d'informations, consultez [la section Création d'un suivi pour une organisation](#) dans la CloudTrail documentation.

gestion du changement organisationnel (OCM)

Cadre pour gérer les transformations métier majeures et perturbatrices du point de vue des personnes, de la culture et du leadership. L'OCM aide les organisations à se préparer et à effectuer la transition vers de nouveaux systèmes et de nouvelles politiques en accélérant l'adoption des changements, en abordant les problèmes de transition et en favorisant des changements culturels et organisationnels. Dans la stratégie de AWS migration, ce cadre est appelé accélération du personnel, en raison de la rapidité du changement requise dans les projets d'adoption du cloud. Pour plus d'informations, veuillez consulter le [guide OCM](#).

contrôle d'accès d'origine (OAC)

Dans CloudFront, une option améliorée pour restreindre l'accès afin de sécuriser votre contenu Amazon Simple Storage Service (Amazon S3). L'OAC prend en charge tous les compartiments S3 dans leur ensemble Régions AWS, le chiffrement côté serveur avec AWS KMS (SSE-KMS) et les requêtes dynamiques PUT adressées au compartiment S3. DELETE

identité d'accès d'origine (OAI)

Dans CloudFront, une option permettant de restreindre l'accès afin de sécuriser votre contenu Amazon S3. Lorsque vous utilisez OAI, il CloudFront crée un principal auprès duquel Amazon S3 peut s'authentifier. Les principaux authentifiés ne peuvent accéder au contenu d'un compartiment S3 que par le biais d'une distribution spécifique CloudFront . Voir également [OAC](#), qui fournit un contrôle d'accès plus précis et amélioré.

OU

Voir l'[examen de l'état de préparation opérationnelle](#).

DE

Voir [technologie opérationnelle](#).

VPC sortant (de sortie)

Dans une architecture AWS multi-comptes, un VPC qui gère les connexions réseau initiées depuis une application. L'[architecture de référence de sécuritéAWS](#) recommande de configurer votre compte réseau avec des VPC entrants, sortants et d'inspection afin de protéger l'interface bidirectionnelle entre votre application et Internet en général.

P

limite des autorisations

Politique de gestion IAM attachée aux principaux IAM pour définir les autorisations maximales que peut avoir l'utilisateur ou le rôle. Pour plus d'informations, veuillez consulter la rubrique [Limites des autorisations](#) dans la documentation IAM.

informations personnelles identifiables (PII)

Informations qui, lorsqu'elles sont consultées directement ou associées à d'autres données connexes, peuvent être utilisées pour déduire raisonnablement l'identité d'une personne. Les

exemples d'informations personnelles incluent les noms, les adresses et les informations de contact.

PII

Voir les [informations personnelles identifiables](#).

manuel stratégique

Ensemble d'étapes prédéfinies qui capturent le travail associé aux migrations, comme la fourniture de fonctions d'opérations de base dans le cloud. Un manuel stratégique peut revêtir la forme de scripts, de runbooks automatisés ou d'un résumé des processus ou des étapes nécessaires au fonctionnement de votre environnement modernisé.

PLC

Voir [contrôleur logique programmable](#).

PLM

Consultez la section [Gestion du cycle de vie des produits](#).

politique

Objet capable de définir les autorisations (voir la [politique basée sur l'identité](#)), de spécifier les conditions d'accès (voir la [politique basée sur les ressources](#)) ou de définir les autorisations maximales pour tous les comptes d'une organisation dans AWS Organizations (voir la politique de contrôle des [services](#)).

persistance polyglotte

Choix indépendant de la technologie de stockage de données d'un microservice en fonction des modèles d'accès aux données et d'autres exigences. Si vos microservices utilisent la même technologie de stockage de données, ils peuvent rencontrer des difficultés d'implémentation ou présenter des performances médiocres. Les microservices sont plus faciles à mettre en œuvre, atteignent de meilleures performances, ainsi qu'une meilleure capacité de mise à l'échelle s'ils utilisent l'entrepôt de données le mieux adapté à leurs besoins. Pour plus d'informations, veuillez consulter [Enabling data persistence in microservices](#).

évaluation du portefeuille

Processus de découverte, d'analyse et de priorisation du portefeuille d'applications afin de planifier la migration. Pour plus d'informations, veuillez consulter [Evaluating migration readiness](#).

predicate

Une condition de requête qui renvoie `true` ou `false`, généralement située dans une `WHERE` clause.

prédicat pushdown

Technique d'optimisation des requêtes de base de données qui filtre les données de la requête avant le transfert. Cela réduit la quantité de données qui doivent être extraites et traitées à partir de la base de données relationnelle et améliore les performances des requêtes.

contrôle préventif

Contrôle de sécurité conçu pour empêcher qu'un événement ne se produise. Ces contrôles constituent une première ligne de défense pour empêcher tout accès non autorisé ou toute modification indésirable de votre réseau. Pour plus d'informations, veuillez consulter [Preventative controls](#) dans *Implementing security controls on AWS*.

principal

Entité AWS capable d'effectuer des actions et d'accéder aux ressources. Cette entité est généralement un utilisateur root pour un Compte AWS rôle IAM ou un utilisateur. Pour plus d'informations, veuillez consulter la rubrique Principal dans [Termes et concepts relatifs aux rôles](#), dans la documentation IAM.

Confidentialité dès la conception

Une approche de l'ingénierie des systèmes qui prend en compte la confidentialité tout au long du processus d'ingénierie.

zones hébergées privées

Conteneur qui contient des informations concernant la façon dont vous souhaitez qu'Amazon Route 53 réponde aux requêtes DNS pour un domaine et ses sous-domaines dans un ou plusieurs VPC. Pour plus d'informations, veuillez consulter [Working with private hosted zones](#) dans la documentation Route 53.

contrôle proactif

[Contrôle de sécurité](#) conçu pour empêcher le déploiement de ressources non conformes. Ces contrôles analysent les ressources avant qu'elles ne soient provisionnées. Si la ressource n'est pas conforme au contrôle, elle n'est pas provisionnée. Pour plus d'informations, consultez le [guide de référence sur les contrôles](#) dans la AWS Control Tower documentation et consultez la section [Contrôles proactifs dans Implémentation](#) des contrôles de sécurité sur AWS.

gestion du cycle de vie des produits (PLM)

Gestion des données et des processus d'un produit tout au long de son cycle de vie, depuis la conception, le développement et le lancement, en passant par la croissance et la maturité, jusqu'au déclin et au retrait.

environnement de production

Voir [environnement](#).

contrôleur logique programmable (PLC)

Dans le secteur manufacturier, un ordinateur hautement fiable et adaptable qui surveille les machines et automatise les processus de fabrication.

pseudonymisation

Processus de remplacement des identifiants personnels dans un ensemble de données par des valeurs fictives. La pseudonymisation peut contribuer à protéger la vie privée. Les données pseudonymisées sont toujours considérées comme des données personnelles.

publier/souscrire (pub/sub)

Modèle qui permet des communications asynchrones entre les microservices afin d'améliorer l'évolutivité et la réactivité. Par exemple, dans un [MES](#) basé sur des microservices, un microservice peut publier des messages d'événements sur un canal auquel d'autres microservices peuvent s'abonner. Le système peut ajouter de nouveaux microservices sans modifier le service de publication.

Q

plan de requête

Série d'étapes, telles que des instructions, utilisées pour accéder aux données d'un système de base de données relationnelle SQL.

régression du plan de requêtes

Le cas où un optimiseur de service de base de données choisit un plan moins optimal qu'avant une modification donnée de l'environnement de base de données. Cela peut être dû à des changements en termes de statistiques, de contraintes, de paramètres d'environnement, de liaisons de paramètres de requêtes et de mises à jour du moteur de base de données.

R

Matrice RACI

Voir [responsable, responsable, consulté, informé \(RACI\)](#).

rançongiciel

Logiciel malveillant conçu pour bloquer l'accès à un système informatique ou à des données jusqu'à ce qu'un paiement soit effectué.

Matrice RASCI

Voir [responsable, responsable, consulté, informé \(RACI\)](#).

RCAC

Voir [contrôle d'accès aux lignes et aux colonnes](#).

réplica en lecture

Copie d'une base de données utilisée en lecture seule. Vous pouvez acheminer les requêtes vers le réplica de lecture pour réduire la charge sur votre base de données principale.

réarchitecte

Voir [7 Rs](#).

objectif de point de récupération (RPO)

Durée maximale acceptable depuis le dernier point de récupération des données. Cela permet de déterminer ce qui est considéré comme une perte de données acceptable entre le dernier point de restauration et l'interruption du service.

objectif de temps de récupération (RTO)

Le délai maximum acceptable entre l'interruption du service et le rétablissement du service.

refactoriser

Voir [7 Rs](#).

Région

Un ensemble de AWS ressources dans une zone géographique. Chacune Région AWS est isolée et indépendante des autres pour garantir la tolérance aux pannes, la stabilité et la résilience. Pour plus d'informations, voir [Spécifier ce que Régions AWS votre compte peut utiliser](#).

régression

Technique de ML qui prédit une valeur numérique. Par exemple, pour résoudre le problème « Quel sera le prix de vente de cette maison ? », un modèle de ML pourrait utiliser un modèle de régression linéaire pour prédire le prix de vente d'une maison sur la base de faits connus à son sujet (par exemple, la superficie en mètres carrés).

réhéberger

Voir [7 Rs](#).

version

Dans un processus de déploiement, action visant à promouvoir les modifications apportées à un environnement de production.

déplacer

Voir [7 Rs](#).

replateforme

Voir [7 Rs](#).

rachat

Voir [7 Rs](#).

résilience

La capacité d'une application à résister aux perturbations ou à s'en remettre. [La haute disponibilité et la reprise après sinistre](#) sont des considérations courantes lors de la planification de la résilience dans le AWS Cloud. Pour plus d'informations, consultez [AWS Cloud Résilience](#).

politique basée sur les ressources

Politique attachée à une ressource, comme un compartiment Amazon S3, un point de terminaison ou une clé de chiffrement. Ce type de politique précise les principaux auxquels l'accès est autorisé, les actions prises en charge et toutes les autres conditions qui doivent être remplies.

matrice responsable, redevable, consulté et informé (RACI)

Une matrice qui définit les rôles et les responsabilités de toutes les parties impliquées dans les activités de migration et les opérations cloud. Le nom de la matrice est dérivé des types de responsabilité définis dans la matrice : responsable (R), responsable (A), consulté (C) et informé (I). Le type de support (S) est facultatif. Si vous incluez le support, la matrice est appelée matrice RASCI, et si vous l'excluez, elle est appelée matrice RACI.

contrôle réactif

Contrôle de sécurité conçu pour permettre de remédier aux événements indésirables ou aux écarts par rapport à votre référence de sécurité. Pour plus d'informations, veuillez consulter la rubrique [Responsive controls](#) dans *Implementing security controls on AWS*.

retain

Voir [7 Rs](#).

se retirer

Voir [7 Rs](#).

rotation

Processus de mise à jour périodique d'un [secret](#) pour empêcher un attaquant d'accéder aux informations d'identification.

contrôle d'accès aux lignes et aux colonnes (RCAC)

Utilisation d'expressions SQL simples et flexibles dotées de règles d'accès définies. Le RCAC comprend des autorisations de ligne et des masques de colonnes.

RPO

Voir l'[objectif du point de récupération](#).

RTO

Voir l'[objectif en matière de temps de rétablissement](#).

runbook

Ensemble de procédures manuelles ou automatisées nécessaires à l'exécution d'une tâche spécifique. Elles visent généralement à rationaliser les opérations ou les procédures répétitives présentant des taux d'erreur élevés.

S

SAML 2.0

Un standard ouvert utilisé par de nombreux fournisseurs d'identité (IdPs). Cette fonctionnalité permet l'authentification unique fédérée (SSO), afin que les utilisateurs puissent se connecter AWS Management Console ou appeler les opérations d'AWS API sans que vous ayez à créer

un utilisateur dans IAM pour tous les membres de votre organisation. Pour plus d'informations sur la fédération SAML 2.0, veuillez consulter [À propos de la fédération SAML 2.0](#) dans la documentation IAM.

SCADA

Voir [Contrôle de supervision et acquisition de données](#).

SCP

Voir la [politique de contrôle des services](#).

secret

Dans AWS Secrets Manager des informations confidentielles ou restreintes, telles qu'un mot de passe ou des informations d'identification utilisateur, que vous stockez sous forme cryptée. Il comprend la valeur secrète et ses métadonnées. La valeur secrète peut être binaire, une chaîne unique ou plusieurs chaînes. Pour plus d'informations, voir [Que contient le secret d'un Secrets Manager ?](#) dans la documentation de Secrets Manager.

contrôle de sécurité

Barrière de protection technique ou administrative qui empêche, détecte ou réduit la capacité d'un assaillant d'exploiter une vulnérabilité de sécurité. Il existe quatre principaux types de contrôles de sécurité : [préventifs](#), [détectifs](#), [réactifs](#) et [proactifs](#).

renforcement de la sécurité

Processus qui consiste à réduire la surface d'attaque pour la rendre plus résistante aux attaques. Cela peut inclure des actions telles que la suppression de ressources qui ne sont plus requises, la mise en œuvre des bonnes pratiques de sécurité consistant à accorder le moindre privilège ou la désactivation de fonctionnalités inutiles dans les fichiers de configuration.

système de gestion des informations et des événements de sécurité (SIEM)

Outils et services qui associent les systèmes de gestion des informations de sécurité (SIM) et de gestion des événements de sécurité (SEM). Un système SIEM collecte, surveille et analyse les données provenant de serveurs, de réseaux, d'appareils et d'autres sources afin de détecter les menaces et les failles de sécurité, mais aussi de générer des alertes.

automatisation des réponses de sécurité

Action prédéfinie et programmée conçue pour répondre automatiquement à un événement de sécurité ou y remédier. Ces automatisations servent de contrôles de sécurité [détectifs](#) ou [réactifs](#)

qui vous aident à mettre en œuvre les meilleures pratiques AWS de sécurité. Parmi les actions de réponse automatique, citons la modification d'un groupe de sécurité VPC, l'application de correctifs à une instance Amazon EC2 ou la rotation des informations d'identification.

chiffrement côté serveur

Chiffrement des données à destination, par celui service AWS qui les reçoit.

Politique de contrôle des services (SCP)

Politique qui propose un contrôle centralisé des autorisations pour tous les comptes d'une organisation dans AWS Organizations. Les SCP définissent des barrières de protection ou des limites aux actions qu'un administrateur peut déléguer à des utilisateurs ou à des rôles. Vous pouvez utiliser les SCP comme listes d'autorisation ou de refus, pour indiquer les services ou les actions autorisés ou interdits. Pour plus d'informations, consultez la section [Politiques de contrôle des services](#) dans la AWS Organizations documentation.

point de terminaison du service

URL du point d'entrée pour un service AWS. Pour vous connecter par programmation au service cible, vous pouvez utiliser un point de terminaison. Pour plus d'informations, veuillez consulter la rubrique [service AWS endpoints](#) dans Références générales AWS.

contrat de niveau de service (SLA)

Accord qui précise ce qu'une équipe informatique promet de fournir à ses clients, comme le temps de disponibilité et les performances des services.

indicateur de niveau de service (SLI)

Mesure d'un aspect des performances d'un service, tel que son taux d'erreur, sa disponibilité ou son débit.

objectif de niveau de service (SLO)

Mesure cible qui représente l'état d'un service, tel que mesuré par un indicateur de [niveau de service](#).

modèle de responsabilité partagée

Un modèle décrivant la responsabilité que vous partagez en matière AWS de sécurité et de conformité dans le cloud. AWS est responsable de la sécurité du cloud, alors que vous êtes responsable de la sécurité dans le cloud. Pour de plus amples informations, veuillez consulter [Modèle de responsabilité partagée](#).

SIEM

Consultez les [informations de sécurité et le système de gestion des événements](#).

point de défaillance unique (SPOF)

Défaillance d'un seul composant critique d'une application susceptible de perturber le système.

SLA

Voir le contrat [de niveau de service](#).

SLI

Voir l'indicateur de [niveau de service](#).

SLO

Voir l'objectif de [niveau de service](#).

split-and-seed modèle

Modèle permettant de mettre à l'échelle et d'accélérer les projets de modernisation. Au fur et à mesure que les nouvelles fonctionnalités et les nouvelles versions de produits sont définies, l'équipe principale se divise pour créer des équipes de produit. Cela permet de mettre à l'échelle les capacités et les services de votre organisation, d'améliorer la productivité des développeurs et de favoriser une innovation rapide. Pour plus d'informations, consultez la section [Approche progressive de la modernisation des applications dans](#) le AWS Cloud

SPOF

Voir [point de défaillance unique](#).

schéma en étoile

Structure organisationnelle de base de données qui utilise une grande table de faits pour stocker les données transactionnelles ou mesurées et utilise une ou plusieurs tables dimensionnelles plus petites pour stocker les attributs des données. Cette structure est conçue pour être utilisée dans un [entrepôt de données](#) ou à des fins de business intelligence.

modèle de figuier étrangleur

Approche de modernisation des systèmes monolithiques en réécrivant et en remplaçant progressivement les fonctionnalités du système jusqu'à ce que le système hérité puisse être mis hors service. Ce modèle utilise l'analogie d'un figuier de vigne qui se développe dans un arbre existant et qui finit par supplanter son hôte. Le schéma a été [présenté par Martin Fowler](#) comme

un moyen de gérer les risques lors de la réécriture de systèmes monolithiques. Pour obtenir un exemple d'application de ce modèle, veuillez consulter [Modernizing legacy Microsoft ASP.NET \(ASMX\) web services incrementally by using containers and Amazon API Gateway](#).

sous-réseau

Plage d'adresses IP dans votre VPC. Un sous-réseau doit se trouver dans une seule zone de disponibilité.

contrôle de supervision et acquisition de données (SCADA)

Dans le secteur manufacturier, un système qui utilise du matériel et des logiciels pour surveiller les actifs physiques et les opérations de production.

chiffrement symétrique

Algorithme de chiffrement qui utilise la même clé pour chiffrer et déchiffrer les données.

tests synthétiques

Tester un système de manière à simuler les interactions des utilisateurs afin de détecter les problèmes potentiels ou de surveiller les performances. Vous pouvez utiliser [Amazon CloudWatch Synthetics](#) pour créer ces tests.

T

balises

Des paires clé-valeur qui agissent comme des métadonnées pour organiser vos AWS ressources. Les balises peuvent vous aider à gérer, identifier, organiser, rechercher et filtrer des ressources. Pour plus d'informations, veuillez consulter la rubrique [Balisage de vos AWS ressources](#).

variable cible

La valeur que vous essayez de prédire dans le cadre du ML supervisé. Elle est également qualifiée de variable de résultat. Par exemple, dans un environnement de fabrication, la variable cible peut être un défaut du produit.

liste de tâches

Outil utilisé pour suivre les progrès dans un runbook. Liste de tâches qui contient une vue d'ensemble du runbook et une liste des tâches générales à effectuer. Pour chaque tâche générale, elle inclut le temps estimé nécessaire, le propriétaire et l'avancement.

environnement de test

Voir [environnement](#).

entraînement

Pour fournir des données à partir desquelles votre modèle de ML peut apprendre. Les données d'entraînement doivent contenir la bonne réponse. L'algorithme d'apprentissage identifie des modèles dans les données d'entraînement, qui mettent en correspondance les attributs des données d'entrée avec la cible (la réponse que vous souhaitez prédire). Il fournit un modèle de ML qui capture ces modèles. Vous pouvez alors utiliser le modèle de ML pour obtenir des prédictions sur de nouvelles données pour lesquelles vous ne connaissez pas la cible.

passerelle de transit

Hub de transit de réseau que vous pouvez utiliser pour relier vos VPC et vos réseaux sur site. Pour plus d'informations, voir [Qu'est-ce qu'une passerelle de transit](#) dans la AWS Transit Gateway documentation.

flux de travail basé sur jonction

Approche selon laquelle les développeurs génèrent et testent des fonctionnalités localement dans une branche de fonctionnalités, puis fusionnent ces modifications dans la branche principale. La branche principale est ensuite intégrée aux environnements de développement, de préproduction et de production, de manière séquentielle.

accès sécurisé

Accorder des autorisations à un service que vous spécifiez pour effectuer des tâches au sein de votre organisation AWS Organizations et dans ses comptes en votre nom. Le service de confiance crée un rôle lié au service dans chaque compte, lorsque ce rôle est nécessaire, pour effectuer des tâches de gestion à votre place. Pour plus d'informations, consultez la section [Utilisation AWS Organizations avec d'autres AWS services](#) dans la AWS Organizations documentation.

réglage

Pour modifier certains aspects de votre processus d'entraînement afin d'améliorer la précision du modèle de ML. Par exemple, vous pouvez entraîner le modèle de ML en générant un ensemble d'étiquetage, en ajoutant des étiquettes, puis en répétant ces étapes plusieurs fois avec différents paramètres pour optimiser le modèle.

équipe de deux pizzas

Une petite DevOps équipe que vous pouvez nourrir avec deux pizzas. Une équipe de deux pizzas garantit les meilleures opportunités de collaboration possible dans le développement de logiciels.

U

incertitude

Un concept qui fait référence à des informations imprécises, incomplètes ou inconnues susceptibles de compromettre la fiabilité des modèles de ML prédictifs. Il existe deux types d'incertitude : l'incertitude épistémique est causée par des données limitées et incomplètes, alors que l'incertitude aléatoire est causée par le bruit et le caractère aléatoire inhérents aux données. Pour plus d'informations, veuillez consulter le guide [Quantifying uncertainty in deep learning systems](#).

tâches indifférenciées

Également connu sous le nom de « levage de charges lourdes », ce travail est nécessaire pour créer et exploiter une application, mais qui n'apporte pas de valeur directe à l'utilisateur final ni d'avantage concurrentiel. Les exemples de tâches indifférenciées incluent l'approvisionnement, la maintenance et la planification des capacités.

environnements supérieurs

Voir [environnement](#).

V

mise à vide

Opération de maintenance de base de données qui implique un nettoyage après des mises à jour incrémentielles afin de récupérer de l'espace de stockage et d'améliorer les performances.

contrôle de version

Processus et outils permettant de suivre les modifications, telles que les modifications apportées au code source dans un référentiel.

Appairage de VPC

Connexion entre deux VPC qui vous permet d'acheminer le trafic à l'aide d'adresses IP privées. Pour plus d'informations, veuillez consulter la rubrique [Qu'est-ce que l'appairage de VPC ?](#) dans la documentation Amazon VPC.

vulnérabilités

Défaut logiciel ou matériel qui compromet la sécurité du système.

W

cache actif

Cache tampon qui contient les données actuelles et pertinentes fréquemment consultées. L'instance de base de données peut lire à partir du cache tampon, ce qui est plus rapide que la lecture à partir de la mémoire principale ou du disque.

données chaudes

Données rarement consultées. Lorsque vous interrogez ce type de données, des requêtes modérément lentes sont généralement acceptables.

fonction de fenêtre

Fonction SQL qui effectue un calcul sur un groupe de lignes liées d'une manière ou d'une autre à l'enregistrement en cours. Les fonctions de fenêtre sont utiles pour traiter des tâches, telles que le calcul d'une moyenne mobile ou l'accès à la valeur des lignes en fonction de la position relative de la ligne en cours.

charge de travail

Ensemble de ressources et de code qui fournit une valeur métier, par exemple une application destinée au client ou un processus de backend.

flux de travail

Groupes fonctionnels d'un projet de migration chargés d'un ensemble de tâches spécifique. Chaque flux de travail est indépendant, mais prend en charge les autres flux de travail du projet. Par exemple, le flux de travail du portefeuille est chargé de prioriser les applications, de planifier les vagues et de collecter les métadonnées de migration. Le flux de travail du portefeuille fournit ces actifs au flux de travail de migration, qui migre ensuite les serveurs et les applications.

VER

Voir [écrire une fois, lire plusieurs](#).

WQF

Consultez le [cadre de qualification des charges de travail AWS](#).

écrire une fois, lire plusieurs (WORM)

Modèle de stockage qui écrit les données une seule fois et empêche leur suppression ou leur modification. Les utilisateurs autorisés peuvent lire les données autant de fois que nécessaire, mais ils ne peuvent pas les modifier. Cette infrastructure de stockage de données est considérée comme [immuable](#).

Z

exploit Zero-Day

Une attaque, généralement un logiciel malveillant, qui tire parti d'une [vulnérabilité de type « jour zéro »](#).

vulnérabilité de type « jour zéro »

Une faille ou une vulnérabilité non atténuée dans un système de production. Les acteurs malveillants peuvent utiliser ce type de vulnérabilité pour attaquer le système. Les développeurs prennent souvent conscience de la vulnérabilité à la suite de l'attaque.

application zombie

Application dont l'utilisation moyenne du processeur et de la mémoire est inférieure à 5 %. Dans un projet de migration, il est courant de retirer ces applications.

Les traductions sont fournies par des outils de traduction automatique. En cas de conflit entre le contenu d'une traduction et celui de la version originale en anglais, la version anglaise prévaudra.